

**UNIVERSIDAD AUTONOMA DE MADRID**

**ESCUELA POLITECNICA SUPERIOR**



**TRABAJO FIN DE MÁSTER**

**Estudio y Análisis de Métodos para la  
Extracción de Características y  
Clasificación de Emociones Basados en  
EEG**

**Máster Universitario en Máster Universitario en  
Investigación e Innovación en TIC (I2-TIC)**

**Autor: BENÍTEZ ALDÁS, Marcos Raphael**

**Tutor: RODRÍGUEZ ORTIZ, Francisco de Borja**

**Departamento de Ingeniería Informática**

**FECHA: Diciembre, 2018**



# **Estudio y Análisis de Métodos para la Extracción de Características y Clasificación de Emociones Basados en EEG**

Autor: BENÍTEZ ALDÁS, Marcos Raphael

Tutor: RODRÍGUEZ ORTIZ, Francisco de Borja

Grupo de Neurocomputación Biológica (GNB)

Dpto. de Ingeniería Informática

Escuela Politécnica Superior

Universidad Autónoma de Madrid

Diciembre 2018



# RESUMEN

El estado emocional de las personas tiene especial impacto en las actividades cotidianas, por ello, lograr una comunicación más real mediante la sensibilidad emocional entre las máquinas y los usuarios, se ha convertido en una meta importante dentro del contexto de las Interfaces Cerebro Computador (BCI). Esto ha permitido la aparición de la Computación Afectiva, la cual, es un campo emergente de estudio enfocado en el desarrollo de dispositivos y aplicaciones que permitan a las máquinas reconocer, analizar e interpretar las emociones humanas mediante diversos tipos de señales fisiológicas, como por ejemplo EEG. Se han logrado importantes avances dentro de este contexto, sin embargo, los sistemas todavía requieren mayor precisión, por lo cual, se hace importante la investigación de nuevos métodos, métricas y procedimientos que permitan mejorar los resultados obtenidos en investigaciones preliminares. Dentro de los diversos métodos utilizados para el reconocimiento de emociones, el uso de señales EEG ha ido ganando popularidad en base a su velocidad y bajo costo.

En el presente Trabajo de Fin de Máster se han estudiado las principales metodologías utilizadas en la Computación Afectiva, enfocándose en el análisis de diversas características que representen de manera significativa a las señales EEG, para construir en base a ellas supervectores de características, que permitan obtener mejores niveles de acierto al aplicar métodos de clasificación de emociones. Para realizar las pruebas, se utilizó principalmente el set de datos SEED y adicionalmente el set de datos DEAP, los cuales constan de señales obtenidas de experimentos realizados mediante la utilización de video, para evocar estados emocionales específicos. Dentro de las características incluidas en el estudio tenemos, las incluidas en el dominio del tiempo, de la frecuencia y de tiempo-frecuencia, las cuales, se combinaron en supervectores, tomando para el efecto aquellas con mayor valor de acierto a nivel individual. Para la realización de las pruebas se utilizó PCA para reducir la dimensionalidad de los datos y SVM polinomial y RBF para la clasificación de emociones. Adicionalmente, se aplicó el método de fuerza bruta para determinar la combinación óptima de canales, logrando mediante su aplicación mejorar en todos los casos los niveles de acierto logrados al utilizar todos los canales en los supervectores.

Al final del estudio se logró mejorar el rendimiento que tendría una aBCI, mediante la fusión de características adecuadas y canales óptimos en un supervector.

### **Palabras Clave:**

Computación afectiva, neurociencia computacional, reconocimiento de emociones, Interfaz Cerebro Computador, supervectores de características, extracción de características, clasificación de emociones, EEG.

# ABSTRACT

The emotional state of people has a special impact on daily activities, therefore, achieving a more real communication through emotional sensitivity between machines and users, has become an important goal within the context of Computer Brain Interfaces (BCI). This has allowed the appearance of Affective Computing, which is an emerging field of study focused on the development of devices and applications that allow machines to recognize, analyze and interpret human emotions through various types of physiological signals, such as EEG. Significant progress has been made in this context, however, the systems still require greater precision, which is why it is important to research new methods, metrics and procedures to improve the results obtained in preliminary investigations. Among the various methods used for the recognition of emotions, the use of EEG signals has been gaining popularity based on its speed and low cost.

In the present study, the main methodologies used in Affective Computing have been studied, focusing on the analysis of diverse characteristics that represent EEG signals in a significant way, to build on them supervectors of characteristics that allow obtaining better levels of success when applying methods of classification of emotions. To carry out the tests, the SEED data set was used mainly and, in addition, the DEAP data set, which consists of signals obtained from experiments carried out using video, to evoke specific emotional states. Within the characteristics included in the study we have those included in the domain of time, frequency and time-frequency, which were combined in supervectors, taking for the effect those with the highest success value at the individual level. For the realization of the tests PCA was used to reduce the dimensionality of the data and polynomial SVM and RBF for the classification of emotions. Additionally, the brute force method was applied to determine the optimal combination of channels, achieving through its application to improve in all cases the success levels achieved by using all the channels in the supervectors.

At the end of the study it was possible to improve the performance that an aBCI would have, by merging adequate characteristics and optimal channels in a supervector.

**Keywords:**

Affective computing, computational neuroscience, emotion recognition, Brain Computer Interface, supervectors of characteristics, extraction of characteristics, emotion classification, EEG.



## Agradecimientos:

A mis hijos Doménica y Ramsés, por su comprensión, pues sé lo difícil que les resultó mi ausencia. A mi esposa Cristina, por ser lo que eres, pues más allá de cualquier circunstancia, siempre nos continuamos apoyando, sabes que puedes contar conmigo.

A mis padres, por creer siempre en mí y darme su apoyo incondicional para esta empresa.

A mi Patria querida y a la Universidad Técnica de Ambato, por brindarme los recursos para hacer realidad esta maravilloso travesía. Al expresidente Rafael Correa Delgado, por cambiar para siempre la educación superior ecuatoriana, mostrándonos el camino hacia una educación de calidad.

A mis amigos y compañeros de la EPS-UAM, en especial a Vinicio, por ser como un hermano mayor en el aprendizaje de la ciencia, por su confianza y apoyo permanente, a Jessica por ser una gran amiga y ayudarme siempre cuando lo necesité, y a Aarón por su confianza y apoyo, gracias a todos por su invaluable amistad.

A mi tutor, Francisco de Borja Rodríguez, por sus enseñanzas y por su paciencia, pero fundamentalmente por creer en mí, arengándome siempre a mejorar, y por abrirme las puertas de la EPS-UAM.

A Verónica Huidobro, por abrirme las puertas de su hogar. Por los gratos momentos vividos, por sus enseñanzas y amistad. La estancia en su casa fue realmente genial.

A mis panas Marco y Wendy, por su confianza, su apoyo y por todas las locuras vividas en Madrid que nunca olvidaré. Ya nos volveremos a encontrar.

A España y a su gente maravillosa, por todo lo vivido, por todo lo aprendido, por todo lo logrado. En especial a Madrid, ciudad de la que me enamoré... me viste caer, me viste llorar, me viste luchar, me viste levantarme y me viste reír. Siempre estarás en mi corazón.

A todos los que aportaron en algo a este proyecto, muchas gracias.

Finalmente, un agradecimiento especial, a esa persona que pese a las circunstancias se atrevió a creer que puede dar siempre más, que se atrevió a viajar, que se atrevió a volar, y que, pese a los fuertes vendavales, no se rindió, que luchó y continuó con valor hasta el final, a quien tuve en este tiempo la posibilidad de conocerlo más, al que me acompaña siempre y al que hoy valoro más... muchas gracias a mí.



# Índice General

RESUMEN .....	iii
Palabras Clave: .....	iv
ABSTRACT.....	v
Keywords:.....	vi
Agradecimientos: .....	vii
Índice General .....	ix
Índice de Figuras .....	xi
Índice de Tablas.....	xiii
1. INTRODUCCIÓN .....	1
1.1.    Ámbito del Trabajo de Fin de Máster .....	1
1.2.    Objetivos .....	2
1.2.1.    Objetivo General: .....	3
1.2.2.    Objetivos Específicos: .....	3
1.3.    Estructura de la Memoria .....	3
2. LAS BCI Y LA COMPUTACIÓN AFECTIVA.....	5
2.1.    Brain Computer Interface (BCI) .....	5
2.1.1.    Tipos de BCIs.....	6
2.1.2.    Fases de las BCI.....	8
2.2.3. Métodos Para Registrar La Actividad Cerebral .....	9
2.2.4. Procesamiento Paralelo Masivo de Señales EEG .....	15
2.2.    La Computación Afectiva .....	17
2.2.1.    Definición .....	17
2.2.2.    Elementos o Fases Principales .....	17
2.2.3.    Las Emociones .....	21
2.2.4.    Importancia de las Emociones .....	21
2.2.5.    Modelos Emocionales.....	23
2.2.6.    Interfaz Cerebro Computador Afectiva (aBCI) .....	27
2.2.7.    Aplicaciones de la Computación Afectiva .....	30
3. ADQUISICIÓN DE DATOS .....	33
3.1. El Set de Datos DEAP [8].....	33
3.2. El Set de Datos SEED [9], [47], [48], [49], [50]. .....	37
4. METODOLOGÍA.....	41
4.1. Obtención de Ondas Cerebrales .....	41
4.2. Métodos de Extracción de Características.....	44
4.2.1. Dominio del Tiempo .....	45

4.2.2. Dominio de la Frecuencia .....	52
4.2.3. Dominio Tiempo-Frecuencia .....	53
4.2.4. Medidas de las Emociones: Valencia y Aerosal .....	54
4.3. Combinación de Características (SUPERVECTORES) .....	55
4.4. Métodos para Clasificación de Emociones .....	57
4.5. Método De Fuerza Bruta .....	60
5. RESULTADOS .....	63
5.1. Pruebas Realizadas con Datos del Set SEED [9]. .....	63
5.1.1. Características Extraídas (pre calculadas) del Set de Datos .....	63
5.1.2. Características Calculadas a partir de las Señales del Set de Datos .....	65
5.2. Pruebas Realizadas con Datos del Set DEAP [8].....	82
6. CONCLUSIONES Y TRABAJO FUTURO .....	85
6.1. Conclusiones .....	85
6.2. Trabajo Futuro.....	87
GLOSARIO.....	89
BIBLIOGRAFÍA:.....	91
A. Mapas de Color de las Búsquedas en Grid de las Pruebas Realizadas.....	95
A.1. Pruebas Realizadas con Datos del Set SEED [9].....	95
A.1.1. Características Extraídas (pre calculadas) del Set de Datos .....	95
A.1.2. Características Calculadas a partir de las Señales del Set de Datos.....	101
A.2. Pruebas Realizadas con Datos del Set DEAP [8]. .....	127

# Índice de Figuras

Figura 1 Principales fases o etapas principales dentro de la implementación de un sistema BCI. El ciclo comienza con la adquisición de la señal, continuando con el procesado de la señal, luego la aplicación y finalizando con el feedback, para posteriormente iniciar el ciclo otra vez. ....	9
Figura 2 Diferentes modalidades de neuroimágenes, entre ellas tenemos: Electrocorticografía (ECoG), Electroencefalografía (EEG), Magnetoencefalografía (MEG), Tomografía de Emisión de Positrones (PET), Imagen de Resonancia Magnética Funcional (fMRI) y Espectroscopía de Infrarrojo Cercano (fNIRS). ....	9
Figura 3 Electrodo para el registro de señales EEG. ....	10
Figura 4 Sistema internacional 10-20. La numeración 10-20 guarda relación con el porcentaje de distancia existente entre los electrodos cercanos, en relación a la distancia total entre los puntos nasión e inión y, entre los puntos preauriculares ubicados a cada lado de la cabeza. Las letras representan regiones cerebrales, tales como Frontopolar (FP), Frontal (F), Temporal (T), Occipital (O), Parietal (P), entre otras, así mismo, los números impares hacen referencia al lado izquierdo del cerebro, mientras los pares al lado derecho y la z a cero [16], [2]. ....	11
Figura 5 Ondas Delta. ....	12
Figura 6 Ondas Theta. ....	12
Figura 7 Ondas Alpha. ....	13
Figura 8 Ondas Beta. ....	13
Figura 9 Ondas Gamma. ....	13
Figura 10 BCI invasivo (Electrocorticografía) [17]. En la gráfica se puede apreciar el dispositivo con los sensores a manera de malla, ubicado directamente sobre la corteza cerebral (áreas sensorial y motora), para lo cual, es necesaria una intervención quirúrgica. ....	14
Figura 11 Rueda de emociones de Robert Plutchik [41], en ella se muestran 8 emociones básicas, cada una con diferentes colores y a su vez con tres estados distintos, desde los más fuertes, ubicados en el interior de la gráfica y con una coloración más intensa, hasta los más débiles ubicados en el exterior de la gráfica, con una coloración tenue. Se puede apreciar que la combinación de dos emociones primarias cercanas genera una emoción secundaria, por ejemplo, al combinar la alegría (en amarillo) con la confianza (verde claro), generan el amor. ....	24
Figura 12 Cubo de Emociones de Lövheim [43]. Cubo de Emociones de Lövheim [43]. Se puede apreciar el origen de los ejes correspondientes a la Noradrenalina, Dopamina y Serotonina en la esquina inferior izquierda del cubo, en donde se muestra que, a medida que los valores de los ejes cambian y se combinan entre sí, generan emociones distintas, por ejemplo, altos valores de Serotonina y Dopamina, pero con bajo valor de Noradrenalina provocan la emoción de alegría. ....	25
Figura 13 Modelo Circumplejo de Emociones original de Russell. Se muestran las emociones básicas asociadas a cada cuadrante, mismos que se generan a partir de la combinación de los ejes Valencia-Aerosal, los cuales se corresponden con el nivel de gusto o disgusto (valencia) y con el nivel de activación o desactivación que puede tener una emoción (aerosal). ....	26
Figura 14 Sitio web del set de datos DEAP [52], [8] . <a href="http://www.eecs.qmul.ac.uk/mmv/datasets/deap/readme.html">http://www.eecs.qmul.ac.uk/mmv/datasets/deap/readme.html</a> ....	33
Figura 15 Organización de los datos set DEAP [52], [8]. <a href="http://www.eecs.qmul.ac.uk/mmv/datasets/deap/readme.html">http://www.eecs.qmul.ac.uk/mmv/datasets/deap/readme.html</a> . ....	35
Figura 16 Sitio web del set de datos SEED [54], [9], [47], [48], [49], [50]. <a href="http://bcmi.sjtu.edu.cn/home/seed/index.html">http://bcmi.sjtu.edu.cn/home/seed/index.html</a> . ....	37
Figura 17 Proceso para la extracción de ondas cerebrales: se inicia con la obtención de las señales EEG, seguido de la especificación del rango de frecuencias para cada tipo de onda y el tiempo	

de muestreo, luego se aplica el filtro Butterworth, para finalmente obtener los distintos tipos de ondas delta, theta, alpha, beta y gamma. ....	42
Figura 18 Ondas alpha.....	43
Figura 19 Método de Fuerza Bruta con Supervector 1.....	73
Figura 20 Método de Fuerza Bruta con Supervector 2.....	74
Figura 21 Método de Fuerza Bruta con Supervector 3.....	75
Figura 22 Método de Fuerza Bruta con Supervector 4.....	76
Figura 23 Método de Fuerza Bruta con Supervector 5.....	77
Figura 24 Método de Fuerza Bruta con Supervector 6.....	78
Figura 25 Método de Fuerza Bruta con Supervector 7.....	79
Figura 26 Método de Fuerza Bruta con Supervector DEAP 1.....	83
Figura 27 Supervector DEAP 2: Búsqueda en grid SVM RBF con PCA (Canales óptimos).....	83
Figura 28 Entropía Diferencial: Búsqueda en grid SVM Polinómico con PCA.....	96
Figura 29 Entropía Diferencial: Búsqueda en grid SVM Polinómico sin PCA.....	96
Figura 30 Entropía Diferencial: Búsqueda en grid SVM RBF con PCA.....	97
Figura 31 Entropía Diferencial: Búsqueda en grid SVM RBF sin PCA.....	97
Figura 32 PSD con Media Móvil: Búsqueda en grid SVM Polinómico con PCA.....	98
Figura 33 PSD con Media Móvil: Búsqueda en grid SVM Polinómico sin PCA.....	98
Figura 34 PSD con Media Móvil: Búsqueda en grid SVM RBF con PCA.....	99
Figura 35 PSD con Media Móvil: Búsqueda en grid SVM RBF sin PCA.....	99
Figura 36 Supervector 0: Búsqueda en grid SVM Polinómico con PCA.....	100
Figura 37 Supervector 0: Búsqueda en grid SVM RBF con PCA.....	100
Figura 38 Media: Búsqueda en grid SVM Polinómico con PCA.....	102
Figura 39 Media: Búsqueda en grid SVM Polinómico sin PCA.....	102
Figura 40 Media: Búsqueda en grid SVM RBF con PCA.....	103
Figura 41 Media: Búsqueda en grid SVM RBF sin PCA.....	103
Figura 42 Valor Máximo: Búsqueda en grid SVM Polinómico con PCA.....	104
Figura 43 Valor Máximo: Búsqueda en grid SVM RBF con PCA.....	104
Figura 44 Valor Mínimo: Búsqueda en grid SVM Polinómico con PCA.....	105
Figura 45 Valor Mínimo: Búsqueda en grid SVM RBF con PCA.....	105
Figura 46 Desviación Típica: Búsqueda en grid SVM Polinómico con PCA.....	106
Figura 47 Desviación Típica: Búsqueda en grid SVM RBF con PCA.....	106
Figura 48 Sesgo: Búsqueda en grid SVM Polinómico con PCA.....	107
Figura 49 Sesgo: Búsqueda en grid SVM RBF con PCA.....	107
Figura 50 Curtosis: Búsqueda en grid SVM Polinómico con PCA.....	108
Figura 51 Curtosis: Búsqueda en grid SVM RBF con PCA.....	108
Figura 52 HJORTH Movilidad: Búsqueda en grid SVM Polinómico con PCA.....	109
Figura 53 HJORTH Movilidad: Búsqueda en grid SVM RBF con PCA.....	109
Figura 54 HJORTH Complejidad: Búsqueda en grid SVM Polinómico con PCA.....	110
Figura 55 HJORTH Complejidad: Búsqueda en grid SVM RBF con PCA.....	110
Figura 56 DFA: Búsqueda en grid SVM Polinómico con PCA.....	111
Figura 57 DFA: Búsqueda en grid SVM RBF con PCA.....	111
Figura 58 Cruces por Cero: Búsqueda en grid SVM Polinómico con PCA.....	112
Figura 59 Cruces por Cero: Búsqueda en grid SVM RBF con PCA.....	112
Figura 60 PSD Simple (Media): Búsqueda en grid SVM Polinómico con PCA.....	113
Figura 61 PSD Simple (Media): Búsqueda en grid SVM RBF con PCA.....	113
Figura 62 PSD Media Móvil (Media): Búsqueda en grid SVM Polinómico con PCA.....	114
Figura 63 PSD Media Móvil (Media): Búsqueda en grid SVM RBF con PCA.....	114

Figura 64 Wavelet db1 (Desviación Estándar): Búsqueda en grid SVM Polinómico con PCA ...	115
Figura 65 Wavelet db1 (Desviación Estándar): Búsqueda en grid SVM RBF con PCA .....	115
Figura 66 HFD: Búsqueda en grid SVM Polinómico con PCA .....	116
Figura 67 HFD: Búsqueda en grid SVM RBF con PCA .....	116
Figura 68 PFD: Búsqueda en grid SVM Polinómico con PCA.....	117
Figura 69 PFD: Búsqueda en grid SVM RBF con PCA .....	117
Figura 70 Valencia: Búsqueda en grid SVM Polinómico con PCA .....	118
Figura 71 Valencia: Búsqueda en grid SVM RBF con PCA .....	118
Figura 72 Supervector 1: Búsqueda en grid SVM Polinómico con PCA.....	119
Figura 73 Supervector 1: Búsqueda en grid SVM RBF con PCA .....	119
Figura 74 Supervector 2: Búsqueda en grid SVM Polinómico con PCA.....	120
Figura 75 Supervector 2: Búsqueda en grid SVM RBF con PCA .....	120
Figura 76 Supervector 3: Búsqueda en grid SVM Polinómico con PCA.....	121
Figura 77 Supervector 3: Búsqueda en grid SVM RBF con PCA .....	121
Figura 78 Supervector 4: Búsqueda en grid SVM Polinómico con PCA.....	122
Figura 79 Supervector 4: Búsqueda en grid SVM RBF con PCA .....	122
Figura 80 Supervector 5: Búsqueda en grid SVM Polinómico con PCA.....	123
Figura 81 Supervector 5: Búsqueda en grid SVM RBF con PCA .....	123
Figura 82 Supervector 6: Búsqueda en grid SVM Polinómico con PCA.....	124
Figura 83 Supervector 6: Búsqueda en grid SVM RBF con PCA .....	124
Figura 84 Supervector 7: Búsqueda en grid SVM Polinómico con PCA.....	125
Figura 85 Supervector 7: Búsqueda en grid SVM RBF con PCA .....	125
Figura 86 Supervector 8: Búsqueda en grid SVM Polinómico con PCA.....	126
Figura 87 Supervector 8: Búsqueda en grid SVM RBF con PCA .....	126
Figura 88 Supervector DEAP 1: Búsqueda en grid SVM RBF con PCA .....	127

## Índice de Tablas

Tabla 1 Métodos de extracción de características y clasificación de emociones. Adaptado y actualizado de [6], con los últimos trabajos respecto al tema. ....	29
Tabla 2 Distribución de electrodos del set de datos DEAP [8]. ....	37
Tabla 3 Listado de canales del set de datos SEED [9]. ....	39
Tabla 4 Combinaciones de características por Supervector y Set de Datos. ....	57
Tabla 5 Resumen de las pruebas con Entropía Diferencial. ....	64
Tabla 6 Resumen de las pruebas con PSD con Media Móvil.....	64
Tabla 7 Resumen de las pruebas con el Supervector 0. ....	65
Tabla 8 Resumen de las pruebas con Media. ....	66
Tabla 9 Resumen de las pruebas con Valor Máximo. ....	66
Tabla 10 Resumen de las pruebas con Valor Mínimo.....	67
Tabla 11 Resumen de las pruebas con Desviación Típica. ....	67
Tabla 12 Resumen de las pruebas con Sesgo o Asimetría. ....	67
Tabla 13 Resumen de las pruebas con Curtosis.....	68
Tabla 14 Resumen de las pruebas con HJORTH Movilidad.....	68
Tabla 15 Resumen de las pruebas con HJORTH Complejidad.....	68
Tabla 16 Resumen de las pruebas con DFA. ....	69
Tabla 17 Resumen de las pruebas con Cruces por Cero .....	69

Tabla 18 Resumen de las pruebas con PSD Simple (Media). .....	69
Tabla 19 Resumen de las pruebas con PSD Media Móvil (Media).....	70
Tabla 20 Resumen de las pruebas con Wavelet DB1 (Desviación Estándar). ....	70
Tabla 21 Resumen de las pruebas con Higuchi Fractal Dimension (HFD). ....	70
Tabla 22 Resumen de las pruebas con Petrosian Fractal Dimension (PFD) .....	71
Tabla 23 Resumen de las pruebas con Valencia .....	71
Tabla 24 Resumen aciertos óptimos características individuales.....	72
Tabla 25 Resumen de las pruebas con Supervector 1 .....	73
Tabla 26 Resumen de las pruebas con Supervector 2 .....	74
Tabla 27 Resumen de las pruebas con Supervector 3 .....	75
Tabla 28 Resumen de las pruebas con Supervector 4 .....	76
Tabla 29 Resumen de las pruebas con Supervector 5 .....	77
Tabla 30 Resumen de las pruebas con Supervector 6 .....	78
Tabla 31 Resumen de las pruebas con Supervector 7 .....	79
Tabla 32 Resumen de las pruebas con Supervector 8 .....	80
Tabla 33 Resumen de valores de acierto máximo tanto al utilizar todos los canales, como al utilizar únicamente los canales óptimos (método de Fuerza Bruta). ....	81
Tabla 34 Resumen de las pruebas con Supervector DEAP 1.....	82



# 1. INTRODUCCIÓN

En esta sección se realiza una breve introducción a este estudio, exponiendo la motivación, objetivos, estructura y contenidos de los capítulos que lo conforman.

## 1.1. Ámbito del Trabajo de Fin de Máster

Las BCI (del inglés Interfaz Cerebro Computador) tienen como objetivo proporcionar un medio para la comunicación y control de un sistema informático que no dependa de movimiento alguno por parte del usuario, y en su lugar, utilizar señales registradas directamente del cerebro o mediante el uso de un enfoque híbrido que combine la actividad cerebral y los registros de otros procesos fisiológicos para generar la interacción persona – computador [1].

Dentro de las BCI, surgen las BCI afectivas (aBCI), las cuales buscan detectar el estado emocional de los usuarios, y usar esa información para que estos interactúen con el computador [1], [2]. De este modo, la computación afectiva permite reconocer, medir e interpretar las emociones humanas por parte de un equipo de cómputo, haciendo posible mediante su investigación y desarrollo, la creación de nuevas tecnologías para mejorar la interacción entre usuarios y máquinas, por ejemplo, en aplicaciones de software educativo en las que se pueda variar la presentación de los contenidos en función de los estados emocionales de los usuarios [3].

De ahí surge el concepto de computación afectiva, misma que abarca tanto el estudio, como el desarrollo de dispositivos que permitan el reconocimiento, análisis e interpretación de las emociones de los usuarios, mediante la captación de sus señales fisiológicas. Dentro de las señales fisiológicas utilizadas para este fin se pueden mencionar: el ritmo cardíaco, ritmo respiratorio, respuesta galvánica de la piel, frecuencia de tensión muscular, reconocimiento facial, entre otras. En este contexto, la utilización de señales electroencefalográficas (EEG) es una de las preferidas por su velocidad y bajo costo, pues se han venido desarrollando equipos que producen buenos resultados a precios cada vez más asequibles y con mayor facilidad de uso como los dispositivos EEG wireless [2], [4].

Las emociones condicionan la capacidad de cognición, toma de decisiones y el normal desarrollo de las actividades humanas [2], [4], por ello, dentro del marco de las interfaces cerebro computador (BCI), el aportar al desarrollo de métodos que permitan realizar un reconocimiento del estado emocional de los usuarios, con niveles cada vez más acertados es de fundamental importancia, siendo esta la principal motivación para la realización de este estudio.

La computación afectiva y las aBCI tienen una amplia gama de aplicaciones potenciales, en áreas que abarcan el entretenimiento, terapias, negocios o educación, haciendo que la experiencia del usuario resulte cada vez más empática y natural con el computador [1], [2].

Por ello, al existir diversos métodos para la extracción de características de las señales registradas y clasificación de emociones, surge la necesidad de realizar un estudio y análisis de estos, con la posibilidad de combinarlos entre sí, para identificar aquellos que nos generen resultados más precisos y que a su vez permitan una interacción más empática entre el computador y los usuarios.

En este trabajo, inicialmente se estudiarán y analizarán los métodos más comunes para la extracción de características y clasificación de emociones basados en EEG. En relación con los métodos de extracción de características de emociones, se propone estudiar y analizar los referentes a dominio de frecuencia [5], dominio del tiempo [5], y métricas estadísticas [5], mientras que en los de clasificación de emociones se lo hará con diversas tecnologías de machine learning [6], [2], [7]. Posteriormente, con los resultados obtenidos se pretende realizar un análisis para determinar las combinaciones de métricas que generen resultados más acertados. Para el estudio se utilizarán los registros de los sets de datos DEAP [8] y SEED [9].

## **1.2. Objetivos**

El presente TFM se enfoca en el estudio y análisis de los principales métodos para la extracción de características y clasificación de emociones basadas en EEG, y en base a

ello, elaborar una combinación óptima de características que mejoren el rendimiento. Se ha planteado para el efecto un objetivo principal, y para conseguirlo 4 específicos.

### **1.2.1. Objetivo General:**

Estudiar los principales métodos y la combinación de técnicas para la extracción de características y clasificación de emociones basadas en señales EEG, que puedan mediante su combinación mejorar el rendimiento.

### **1.2.2. Objetivos Específicos:**

1. Elaborar el estado del arte referente a la Computación Afectiva y a los métodos de extracción de características y clasificación de emociones basadas en EEG.
2. Buscar y estudiar sets de datos adecuados para la aplicación de los métodos de extracción de características y clasificación de emociones basadas en EEG.
3. Estudiar y aplicar sobre los sets de datos los métodos para la extracción de características y clasificación de emociones basadas en EEG.
4. Buscar posibles combinaciones de diversas técnicas y métricas para aumentar el nivel de acierto en el contexto del reconocimiento de emociones basadas en EEG.

## **1.3. Estructura de la Memoria**

Esta memoria consta de seis capítulos, los cuales se detallan a continuación:

- El primer capítulo que incluye una breve introducción en la cual destaca el ámbito del Trabajo de Fin de Máster y la motivación del mismo, los objetivos que se persiguen y el detalle de la estructura de la memoria.
- El segundo capítulo abarca el estado del arte de la Computación Afectiva, en el cual se inicia con una descripción de los BCIs, para luego introducirnos a los aBCIs como parte de la Computación Afectiva, de la cual abordaremos sus conceptos fundamentales, usos e investigaciones relevantes.
- En el tercer capítulo se explican los sets de datos de los que se obtuvo las señales EEG para realizar las pruebas, estudio y análisis correspondientes.

- En el cuarto capítulo se aborda la metodología utilizada para la extracción de características, clasificación de emociones basadas en EEG y la creación de supervectores de características.
- El quinto capítulo presenta los resultados obtenidos en las pruebas realizadas sobre los diferentes sets de datos.
- El sexto capítulo expone las conclusiones, discusión y trabajos futuros.
- En el apéndice se exponen imágenes de los mapas de color de las búsquedas en grid de los resultados de cada una de las pruebas realizadas.

## **2. LAS BCI Y LA COMPUTACIÓN AFECTIVA**

En esta sección se exponen conceptos fundamentales sobre las BCI, como su definición, tipos, componentes principales, métodos para registrar la señal, y el procesamiento masivo de señales EEG. Así mismo, de la Computación Afectiva se exponen su definición, componentes principales, conceptos básicos e importancia de las emociones, principales modelos emocionales, interfaces cerebro computador afectivas y ejemplos de aplicaciones de la computación afectiva.

### **2.1. Brain Computer Interface (BCI)**

Una interfaz cerebro computador (BCI), es un dispositivo que traduce señales provenientes de la actividad cerebral en comandos dirigidos a una aplicación interactiva [10]. Tal es el caso de dispositivos que permiten, por ejemplo, la movilidad de personas parapléjicas a través de la generación de comandos que permiten controlar una silla de ruedas eléctrica, basados en las señales cerebrales de los usuarios obtenidas mediante electrodos.

Desde que se iniciaron los estudios en esta área, por ejemplo, demostrando que se podía mover un brazo robótico empleando señales obtenidas de la actividad eléctrica de grupos de neuronas corticales, las investigaciones han ido en constante aumento [11].

Los BCI poseen 2 características que los diferencian de otros sistemas de interfaz persona-máquina:

- Se crea un canal de comunicación natural entre el usuario y la máquina pues las intenciones se traducen en comandos directamente, sin necesitar adaptarse al tipo de interfaz.
- Se puede acceder a información mental y afectiva de los usuarios.

### 2.1.1. Tipos de BCIs

Existen múltiples clasificaciones de los BCIs propuestas por varios autores: [7], [11], [12], [13], de las cuales, debido a su fácil comprensión se han elegido:

1. Por la ubicación de los sensores.
2. Por el modo de operación.
3. Por la estrategia de operación.

A continuación, se detallan estos puntos:

**2.1.1.1. Por la ubicación de los sensores:** En función a la posición interna o externa de los sensores respecto al cuerpo humano.

- **No invasivas:** Se toman los datos de las señales desde el cuero cabelludo mediante electrodos secos o húmedos. Un ejemplo de BCI no invasivo es la Electroencefalografía (EEG). Su ventaja principal es la facilidad de utilización y no conlleva riesgo para los usuarios debido a que no es necesaria la intervención quirúrgica [11].
- **Invasivas:** Los electrodos para la obtención de los datos son implantados en forma intracraneal. Las señales obtenidas mediante este método son de mejor calidad que las obtenidas con métodos no invasivos, pero a su vez conllevan riesgo para los usuarios pues se hace necesaria la intervención quirúrgica [11]. A su vez los BCI Invasivos se pueden clasificar en:
  - *Single Recording Site:* Permiten registrar información de un área cortical específica.
  - *Multiple Recording Site:* Permiten registrar información de múltiples áreas corticales a la vez.

**2.1.1.2. Por el modo de operación:** En función al modo en que son evocadas y empleadas las señales cerebrales.

- **Activas:** El usuario genera las señales de manera consciente, por ejemplo, al imaginar el movimiento de uno de sus brazos. Se utilizan principalmente para enviar comandos voluntarios a una aplicación o dispositivo [11], [12].
- **Reactivas:** Las señales son evocadas a través de estímulos como imágenes, videos, sonidos, luces, olores [11], [12].
- **Pasivas:** Se emplean para monitorear estados mentales de los usuarios como estrés, angustia, atención, etc., para luego adaptar la aplicación objetivo de acuerdo con este estado. Dentro del grupo de las BCI pasivas se incluyen las BCI afectivas (aBCI), que monitorean estados afectivos o emociones como alegría o calma. La finalidad de las aBCI radica en diseñar aplicaciones que reaccionen a estos estados [11], [12].

**2.1.1.3. Por la estrategia de operación:** En función al nivel de entrenamiento que requieren los usuarios para controlar voluntariamente sus propias señales cerebrales.

- **Endógenas:** Son aquellos que dependen de la capacidad que tengan los usuarios para controlar voluntariamente sus propias señales cerebrales y utilizarlas así para un fin determinado. Para lograr este fin se requiere una fase de entrenamiento intenso por parte del usuario. Dentro del ámbito de los BCI endógenos tenemos a los BCI basados en potenciales corticales lentos SCP y a los BCI basados en imágenes motoras [13].
- **Exógenas:** En este caso los usuarios no necesitan demasiado entrenamiento pues estos BCI utilizan señales evocadas en base a estímulos externos. Dentro de este grupo tenemos a los BCI basados en potenciales evocados P300 y a los BCI basados en potenciales evocados de estado estable SSVEP [13].

### **2.1.2. Fases de las BCI**

En la implementación de las BCI se pueden diferenciar varias fases o etapas (figura 1), dentro de las cuales se consideran:

1. Adquisición de señal.
2. Procesado de la señal.
3. Aplicación.
4. Feedback

A continuación, se detallan estos puntos:

#### **2.1.2.1. Adquisición de Señal:**

En esta etapa se adquiere la señal cerebral analógica mediante sensores. La señal puede obtenerse por distintos métodos como: EEG, fMRI, ECoG, PET, fNIRS. Se procede a amplificar la señal y a digitalizarla [13].

#### **2.1.2.2. Procesado de la Señal:**

En esta etapa se procede a extraer las características relevantes de la señal para proceder a transformarla en comandos entendibles por el dispositivo.

Como parte inicial del procesado de la señal se remueven los artefactos y se aplican filtros espaciales y temporales. Posteriormente se extraen las características y se las clasifica [7].

#### **2.1.2.3. Aplicación:**

En esta etapa se reciben los comandos enviados en la etapa anterior y se ejecutan las acciones en el dispositivo [13].

#### **2.1.2.4. Feedback:**

Dependiendo del tipo de aplicación que se realice, las señales procesadas, pueden proveer una retroalimentación o feedback a los usuarios [13].






*Figura 1 Principales fases o etapas principales dentro de la implementación de un sistema BCI. El ciclo comienza con la adquisición de la señal, continuando con el procesamiento de la señal, luego la aplicación y finalizando con el feedback, para posteriormente iniciar el ciclo otra vez.*

### 2.2.3. Métodos Para Registrar La Actividad Cerebral

Existen diversos métodos para registrar la actividad cerebral, los más relevantes se detallan en la figura 2, continuando luego con una breve explicación de estos, prestando mayor atención a la electroencefalografía (EEG), debido a que es parte fundamental del presente estudio.



*Figura 2 Diferentes modalidades de neuroimágenes, entre ellas tenemos: Electroencefalografía (EEG), Magnetoencefalografía (MEG), Tomografía de Emisión de Positrones (PET), Imagen de Resonancia Magnética Funcional (fMRI) y Espectroscopía de Infrarrojo Cercano (fNIRS).*

### 2.2.3.1. Electroencefalografía (EEG)

Es uno de los más populares métodos no invasivos para obtener registros de la actividad cerebral. Para obtener los registros de las señales se ubican sobre el cuero cabelludo varios electrodos a manera de un casco (figura 3). En cada electrodo se registra las señales de grupos de neuronas [14].



*Figura 3 Electrodos para el registro de señales EEG.*

Para registrar las señales cerebrales un casco EEG debe constar al menos de 3 electrodos (tierra, referencia y registro), un amplificador y un conversor análogo digital. Existe un estándar internacionalmente reconocido para realizar los registros EEG, y es el sistema 10-20 (figura 4). Este consta originalmente de 21 electrodos con posiciones establecidas, sin embargo, se pueden implementar muchos más [15].





Figura 4 Sistema internacional 10-20. La numeración 10-20 guarda relación con el porcentaje de distancia existente entre los electrodos cercanos, en relación a la distancia total entre los puntos nasión e inión y, entre los puntos preauriculares ubicados a cada lado de la cabeza. Las letras representan regiones cerebrales, tales como Frontopolar (FP), Frontal (F), Temporal (T), Occipital (O), Parietal (P), entre otras, así mismo, los números impares hacen referencia a electrodos situados en el hemisferio izquierdo del cerebro, mientras los pares a electrodos situados en el hemisferio derecho, y la z a los situados en la línea que va desde el nasión hasta el inión [16], [2].

En los registros EEG se pueden diferenciar tipos de ondas o ritmos en rangos de frecuencias específicos. En las figuras 5, 6, 7, 8 y 9, se exponen en forma ilustrativa las gráficas de las ondas delta, theta, alpha, beta y gamma respectivamente, mismas que han sido obtenidas en las pruebas realizadas en este estudio, con datos de la señal EEG correspondientes al canal 1 del experimento 1 del archivo “zhujiayi\_20130709.mat” del set de datos SEED [9], mediante la aplicación de un filtro pasabanda tipo Butterworth, entre los rangos de frecuencia descritos en los siguientes párrafos para cada tipo de onda, y con un número de orden igual a 9. Una explicación más detallada de la metodología utilizada se encuentra en la sección 4.1, así como, mayor información sobre el set de datos SEED [9], en la sección 3.2.


No existe un acuerdo específico respecto del límite inferior y superior de frecuencia de cada ritmo, sin embargo, según varios autores [8], [9], se procede a tomar como base los límites de frecuencia que se proponen a continuación en la explicación de cada tipo de onda o ritmo cerebral: Delta, Theta, Alpha, Beta y Gamma.

**Ondas Delta:** Su frecuencia oscila entre 1 y 4 Hz. Se asocia a estados de inconsciencia y de sueño profundo. Tienen mayor amplitud que el resto de las ondas cerebrales, así como menor frecuencia [2]. Se pueden observar en la figura 5.




*Figura 5 Ondas Delta.*

**Ondas Theta:** Su frecuencia oscila entre 4 y 8 Hz. Se asocia a estados de sueño ligero y calma profunda, así como a estados de introspección personal. Se las asocia también a la mente subconsciente, y a la realización de actividades en que la persona ha creado hábitos, por lo cual, actúa de manera mecánica sin poner plena consciencia de sus acciones, llegando incluso a no recordar lo que ha realizado [2]. Se pueden observar en la figura 6.




*Figura 6 Ondas Theta.*

**Ondas Alpha:** Su frecuencia oscila entre 8 y 14 Hz. Se asocian a estados mentales despiertos, pero con relajación profunda o inactividad. La mayor actividad de este tipo de ondas se asocia a los lóbulos parietal y occipital. Se las relaciona con estados de inactividad mental, por ejemplo, en los intervalos de descanso entre jornadas de estudio [2]. Se pueden observar en la figura 7.




*Figura 7 Ondas Alpha.*

**Ondas Beta:** Su frecuencia oscila entre 14 y 31 Hz. Se las asocia a estados mentales despiertos, intensos y de alerta, por ejemplo, al mantener una conversación con clientes o participar en una competencia. La mayor concentración de actividad de este tipo de ondas se ubica en la corteza prefrontal y en áreas específicas relacionadas a la actividad mental realizada. Son ondas con baja amplitud y alta frecuencia [2]. Se pueden observar en la figura 8.



*Figura 8 Ondas Beta.*

**Ondas Gamma:** Su frecuencia oscila entre 31 y 50 Hz. Se las asocia a una alta actividad cerebral y por ende a un mayor rendimiento cognitivo. Tienen menor amplitud que el resto de ondas, así como mayor frecuencia [2]. Se pueden observar en la figura 9.




*Figura 9 Ondas Gamma.*

### 2.2.3.2. Magnetoencefalografía (MEG)

Es un método no invasivo que se caracteriza por registrar las señales cerebrales mediante el uso de campos magnéticos. Mediante esta técnica se obtiene información del funcionamiento anatómico del cerebro. Su desventaja principal es el espacio que ocupa el dispositivo para registrar las señales [14].

### 2.2.3.3. Electrocorticografía (ECoG)

Es un método invasivo caracterizado por ubicar los electrodos para registrar la actividad cerebral directamente sobre la corteza cerebral (figura 10). Para este cometido es necesario realizar al paciente una intervención quirúrgica. La ventaja de esta técnica es que se consiguen registrar las señales cerebrales con mayor fidelidad [14].



*Figura 10 BCI invasivo (Electrocorticografía) [17]. En la gráfica se puede apreciar el dispositivo con los sensores a manera de malla, ubicado directamente sobre la corteza cerebral (áreas sensorial y motora), para lo cual, es necesaria una intervención quirúrgica.*

### 2.2.3.4. Imagen de Resonancia Magnética Funcional (fMRI)

La fMRI se basa en el principio de funcionamiento de la Resonancia Magnética Nuclear. Registra los cambios generados en el flujo sanguíneo como resultado de la actividad cerebral. Permite registrar la actividad cerebral mientras se realizan tareas. Es ampliamente utilizado para estudios de la memoria [14].

#### **2.2.3.5. Tomografía de Emisión de Positrones (PET)**

Para la realización de esta técnica, se administra al paciente una sustancia radioactiva llamada radiosondas. Con la ayuda del equipo y gracias a la sustancia administrada se logra visualizar la actividad metabólica de las células. Por sus características a esta técnica se la incluye como parte de la Medicina Nuclear [14].

#### **2.2.3.6. Espectroscopía de Infrarrojo Cercano Funcional (fNIRS)**

En esta técnica el equipo emite un haz de luz infrarroja al tejido, misma que es registrada a su retorno por el mismo equipo. Con ello es posible medir los cambios del nivel de oxígeno en áreas del cerebro en tiempo real. Se utiliza para investigar los cambios que ocurren en el cerebro al realizar determinadas actividades [14].

#### **2.2.4. Procesamiento Paralelo Masivo de Señales EEG**

En este apartado se exponen propuestas relacionadas al procesamiento paralelo masivo de señales electroencefalográficas (EEG). Como factor común en diversas investigaciones, se propone la utilización de GPUs para paralelizar mejor los procesos, debido a la potencia de estos dispositivos, que sumados a su natural capacidad de paralelización generan resultados muy superiores en desempeño que al usar CPUs, sin embargo, también se recomienda el uso de CPUs multicore superescalares de multipropósito general [18], [19], [20], [21].

Una propuesta de Juan José Escobar et al. [21], nos exponen que las arquitecturas paralelas heterogéneas que incluyen CPUs multicore de propósito general superescalar y aceleradores, principalmente las que incluyen GPUs, constituyen el enfoque más ventajoso.

Los mismos autores, en otro de sus artículos [22], realizan una revisión sobre el diseño eficiente de procedimientos paralelos para la clasificación y optimización de tareas con alta dimensionalidad, mismas que fueron ejecutadas sobre arquitecturas paralelas heterogéneas, dentro de las cuales se incluyen CPUs multicore y GPUs. Proponen un

procedimiento paralelo OpenCL que permite una distribución dinámica de la carga de trabajo entre los núcleos de plataformas heterogéneas, incluidas las arquitecturas CPU y GPU multinúcleo.

Chen et al. [23], hace referencia a tres grandes retos a alcanzar en el procesamiento masivo de señales cerebrales: eficiencia, escalabilidad y confiabilidad, para lo cual aseguran es necesario el concurso de tecnologías de punta como: Unidades de Propósito General (GPGPU), pues su arquitectura es masivamente paralela y en gran medida más potentes que una CPU.

Se puede anticipar que, en un futuro no lejano, las tecnologías de computación híbrida que combinan GPGPU y computación distribuida y paralela de punta, prevalecerán en el proceso de análisis de señales neurológicas masivas con un acelerado incremento en su densidad y canales [21].

Hay que destacar además que, en el artículo de Z. Juhasz [24], se sugiere que todas las fases del procesamiento de una señal (desde el preprocesamiento hasta la clasificación) pueden ejecutarse en tiempo real en una GPU, lo cual abre la posibilidad de utilizarlos en aplicaciones de monitoreo y diagnóstico en tiempo real, tales como sistemas BCI avanzados, diagnóstico de enfermedades de tipo neuronal, toma de imágenes cerebrales de alta resolución y diagnóstico cardiaco.

Con la popularización de los GPGPU, se plantea a futuro la posibilidad de reducir drásticamente el tamaño de los dispositivos para generar una cada vez mayor facilidad de uso y portabilidad, con el necesario incremento paulatino de las capacidades de procesamiento paralelo que estos equipos brindan, tomando en consideración que en varias enfermedades relacionadas por ejemplo a desordenes del sueño, la constante monitorización puede permitir obtener ayuda valiosa para el tratamiento de las mismas [25].



## **2.2. La Computación Afectiva**

En esta sección se exponen conceptos fundamentales sobre la Computación Afectiva, como su definición, componentes principales, conceptos básicos e importancia de las emociones, principales modelos emocionales, las interfaces cerebro computador afectivas y ejemplos de aplicaciones de la Computación Afectiva.

### **2.2.1. Definición**

La Computación Afectiva es un área de estudio e investigación emergente, que busca crear nuevo software e incluso hardware que tenga en cuenta la carga emocional de las personas. Estos dispositivos deben ser capaces de reconocer, interpretar y procesar emociones humanas, mismas que la psicología denomina también estados de ánimo o estados afectivos. En este contexto se encuentran inmersas las BCI, pues en base al reconocimiento de las emociones de los usuarios mediante señales EEG, se mejoraría en gran medida la interacción Humano-máquina, siendo este uno de los objetivos de la Computación Afectiva [26]. El término Computación Afectiva (Affective Computing) fue acuñado por Rosalind Picard [27] en el año 1995, publicando además un libro con el mismo nombre.

### **2.2.2. Elementos o Fases Principales**

Según Yannakakis G. [28] la evocación de emociones genera manifestaciones corporales, las cuales pueden ser detectadas y modeladas, por ello, plantea que la Computación Afectiva tiene 4 fases o elementos principales, las cuales generan un ciclo cerrado, al cual se lo denomina bucle afectivo, mismo que está constituido por:

1. Evocación Afectiva
2. Detección Afectiva
3. Modelado Afectivo
4. Adaptación Impulsada por Afectos

A continuación, se detallan estos puntos:

### 2.2.2.1. Evocación Afectiva:

En esta fase se pretende evocar emociones en el usuario. Para ello se utilizan diversas técnicas como por exponer al usuario a imágenes, audios, videos, etc., con contenido emocional, existiendo en algunos casos sistemas estandarizados para el efecto. En campos como la atención médica estos evocadores pueden ser también imágenes y sonidos asociados con traumas, interacción social con otros pacientes, entornos digitales en terapia virtual, entre otros [28].

- **Imágenes:** Uno de los métodos más utilizados es el empleo de imágenes con contenido emocional, por ejemplo, se pueden evocar emociones positivas a través de la presentación de imágenes de niños jugando o de personas sonrientes, de igual manera, se pueden evocar emociones negativas con imágenes que muestren contenido violento. Para el efecto existen bancos de imágenes emocionales estandarizadas, entre las cuales se tienen los sets de datos IAPS [29], u OASIS [30].
- **Sonido:** Se evocan las emociones mediante la aplicación de audios emocionales, los cuales previamente son asociados a determinadas emociones, por ejemplo mediante la aplicación de audios con sonidos molestos o estridentes se pueden generar emociones negativas, a su vez, con audios de naturaleza se pueden generar estados emocionales de calma [31].
- **Video:** Se evocan las emociones mediante la aplicación de videos emocionales. Tal es el caso de los sets de datos para reconocimiento emocional DEAP [8], MAHNOB-HCI [32], y SEED [9]. En este estudio se analizan los sets de datos DEAP [8], y SEED [9], mismos que se explican en detalle en la sección 3.

### 2.2.2.2. Detección Afectiva:

El sistema detecta las reacciones corporales o fisiológicas del individuo, generadas por la evocación afectiva. En este paso también se procede a etiquetar las emociones capturadas, por ejemplo, en emociones positivas, negativas o neutras [28]. Dentro de los múltiples medios que existen para registrar las señales que permitan el reconocimiento emocional de un usuario podemos destacar:

1. Detección Facial o Corporal
2. Tono de Voz
3. Señales Fisiológicas

A continuación, se detallan estos puntos:

- **Detección Facial o Corporal**

Los sistemas que reconocen las emociones se basan en codificar la acción facial mediante el análisis de un conjunto de movimientos específicos localizados de la cara, llamados Unidades de Acción, para codificar la expresión facial. Estos se pueden reconocer a partir de características geométricas y de características de apariencia extraídas de un repositorio de imágenes faciales [33]. Por ejemplo, para realizar el reconocimiento emocional en el contexto, se utiliza la base de datos EMOTIC [33], que contiene imágenes de personas en un contexto específico, tales como, en una práctica deportiva o en una reunión de amigos. Cada imagen de la base combina dos tipos de anotaciones: las 26 categorías emocionales y las tres dimensiones emocionales (Valencia, Excitación y Dominio). Esta tecnología es capaz de reconocer los sentimientos de la misma manera que los humanos, y puede generar muchas aplicaciones potenciales en la interacción humana con la computadora [33].

- **Tono de Voz**

Al igual que en los sistemas de detección facial, los sistemas de reconocimiento de emociones de la voz (REV), consta de una base de datos inicial con grabaciones de voces asociadas a distintas emociones, para en base a estos patrones realizar el reconocimiento emocional [34].

- **Señales Fisiológicas**

El reconocimiento de emociones se realiza a través de múltiples señales fisiológicas como el ritmo cardiaco, ritmo respiratorio, respuesta galvánica de la piel, frecuencia de tensión muscular, entre otras, dentro de las cuales la utilización de señales electroencefalográficas (EEG) es una de las preferidas por su velocidad y bajo costo, pues se han venido desarrollando equipos que producen buenos

resultados a precios cada vez más asequibles y con mayor facilidad de uso como los dispositivos EEG wireless [2], [4].

Para establecer parámetros de comparación entre los diferentes métodos, podemos decir que la electroencefalografía (EEG), es una técnica de medición de señales neuronales más eficaz y accesible económicamente, en relación con las técnicas de imagen por resonancia magnética funcional (fMRI) y magnetoencefalografía (MEG). Mediante EEG se han logrado valoraciones de experiencias emocionales mediante la clasificación valencia y aerosal, lo cual ha servido de base para el desarrollo de modelos de reconocimiento emocional [35].

Por otro lado, el estudio de las experiencias entre varios individuos mediante fMRI, ha mostrado que se pueden comparar aspectos mediante el promedio de correlaciones de Pearson, que concluyen en la obtención de características similares y por lo tanto de tendencias poblacionales [35].

El uso de EEG en el estudio de características cerebrales de varias personas, podría generar resultados importantes a futuro, ya que, se ha podido determinar que la correlación inter-cerebral de la amplitud de los ritmos alfa y beta obtenidos sobre regiones frontales, se relacionaron con la comprensión de las intenciones de otras personas y las estrategias de cooperación de alto nivel. Del mismo modo, al analizar la consistencia inter-cerebral de la amplitud del ritmo Delta, se podrían obtener datos sobre las preferencias de comportamiento de grupos de personas. Por tanto, el estudio de varias personas enfocado a bandas de frecuencias específicas, puede representar un avance para una mejor comprensión de los aspectos cognitivos y emocionales de grupos humanos, lo cual representa una ventaja al utilizar señales EEG [35].

#### **2.2.2.3. Modelado Afectivo:**

En esta fase se elabora el modelo que relacione las emociones evocadas en el usuario y las reacciones fisiológicas o corporales obtenidas. Las actividades inmersas en esta fase son el procesamiento de los datos, la extracción de características y la clasificación de emociones. Para ello se recurren a métodos de machine learning como: vecinos cercanos, SVM, árboles de decisión, random forest, redes neuronales, aprendizaje profundo, entre

otras [28]. Los métodos para la extracción de características se exponen en mayor detalle en la sección 4.2, y los métodos para clasificación de emociones en la sección 4.4.

#### **2.2.2.4. Adaptación Impulsada por Afectos:**

El sistema se adapta al estado actual de la persona. Por citar un ejemplo: si el sistema detecta que la persona está triste, buscará música que evoque pensamientos alegres en el usuario. De esta manera se cierra el ciclo, retornando a la primera fase [28].

### **2.2.3. Las Emociones**

En el ámbito de la Psicología existen varias definiciones del término “emoción”, sin embargo, dada la complejidad del mundo emocional, ninguna llega a satisfacer plenamente lo que una emoción puede significar.

Denzin [36], define a las emociones en términos de experiencias corporales percibidas internamente y a través del cuerpo, las cuales, en el tiempo que duran, van sumiendo al individuo y a quienes lo rodean en una realidad transformada.

A las emociones también se las puede considerar como eventos que ocurren en función de sucesos internos o externos al organismo, los cuales generan cambios en sus diversos componentes [37].

Estudiar las emociones es un tema complejo debido a que tienen una dinámica de constantes cambios y transformaciones dentro de los seres humanos, tanto de manera consciente como inconsciente. Por ejemplo: la vergüenza puede trastocarse en rabia [38].

### **2.2.4. Importancia de las Emociones**

Históricamente en el ámbito de lo científico y tecnológico, las emociones humanas han tenido poca importancia frente a lo puramente racional, en gran medida por el alto grado de subjetividad que la investigación en estas radica [21].

Pese a ello, estudios neurológicos muestran lo esenciales que son las emociones en la cognición humana, pues tienen gran influencia en aspectos como:

- Toma de decisiones
- Percepción
- Interacción humana
- Inteligencia

Así, pese a los avances tecnológicos, la interacción entre un sistema de cómputo y un ser humano no es realmente completa sin la participación de las emociones. Por ello, surge la Computación Afectiva.

Según R. Picard [27], un sistema que tenga emociones debería tener cinco componentes fundamentales:

- Emociones emergentes
- Emociones primarias
- Emociones cognitivas
- Experiencia emocional
  - Ser consciente de la propia emocionalidad
  - Manifestaciones fisiológicas
- Interacciones cuerpo-mente
  - Las emociones afectan a la cognición

Por la importancia que tienen las emociones en múltiples aspectos, el interés por lograr una mayor interacción cerebro máquina ha crecido notablemente en los últimos años, lo cual se puede apreciar en el incremento de trabajos que se han ido desarrollando al respecto [5].

En el informe Hype Cycle for Emerging Technologies [39], mismo que ofrece una perspectiva multisectorial sobre tecnologías y tendencias emergentes a nivel mundial dentro del contexto de I+D, se muestra que, tanto la Computación Afectiva como las BCI se enmarcan dentro del estado de activación de la innovación, y que, según las predicciones de los autores, tardarán entre cinco y diez años para la Computación

Afectiva y más de diez años en el caso de los BCI, para llegar tener una adopción general en el mercado.

### **2.2.5. Modelos Emocionales**

Para facilitar el estudio de las emociones, se han propuesto modelos teóricos de las mismas, los cuales son una representación o abstracción de la realidad para facilitar su estudio, tal como por ejemplo, un modelo a escala del sistema solar, se basan en los cambios que realizan las emociones en diversos componentes como: valencia-aerosal, cambios hormonales, etc., lo cual permite medirlas y clasificarlas con mayor facilidad [37]. A continuación, se exponen algunos modelos emocionales que resultan de interés para el reconocimiento de emociones dentro del ámbito de la Computación Afectiva:

1. Rueda de Emociones de Plutchik
2. Cubo de Emociones de Lövheim
3. Modelo Circunflejo de Russell

A continuación, se detallan estos puntos:

#### **2.2.5.1. Rueda de Emociones de Plutchik**

El Psicólogo Estadounidense Robert Plutchik [40], propuso un sistema de emociones en las que a manera los colores, existen emociones básicas y al combinarlas entre sí se obtienen las emociones avanzadas. Adicionalmente cada emoción tiene 3 estados, por ejemplo: la alegría sería el nivel medio, la serenidad el nivel bajo y el éxtasis el nivel alto. Esto ocurre solo para las emociones básicas. En la figura 11 se puede apreciar con mayor claridad lo expuesto.




Figura 11 Rueda de emociones de Robert Plutchik [41], en ella se muestran 8 emociones básicas, cada una con diferentes colores y a su vez con tres estados distintos, desde los más fuertes, ubicados en el interior de la gráfica y con una coloración más intensa, hasta los más débiles ubicados en el exterior de la gráfica, con una coloración tenue. Se puede apreciar que la combinación de dos emociones primarias cercanas genera una emoción secundaria, por ejemplo, al combinar la alegría (en amarillo) con la confianza (verde claro), generan el amor.

## 2.2.5.2. Cubo de Emociones de Lövheim

Lövheim [42], propuso un modelo tridimensional de las emociones, en el cual se ubican 8 emociones básicas. Los 3 ejes del cubo representan la Serotonina, la Noradrenalina y la Dopamina. En los ejes se indican los niveles de mayor o menor cantidad de cada una de las hormonas. En la figura 12 se aprecia con mayor detalle lo expuesto.



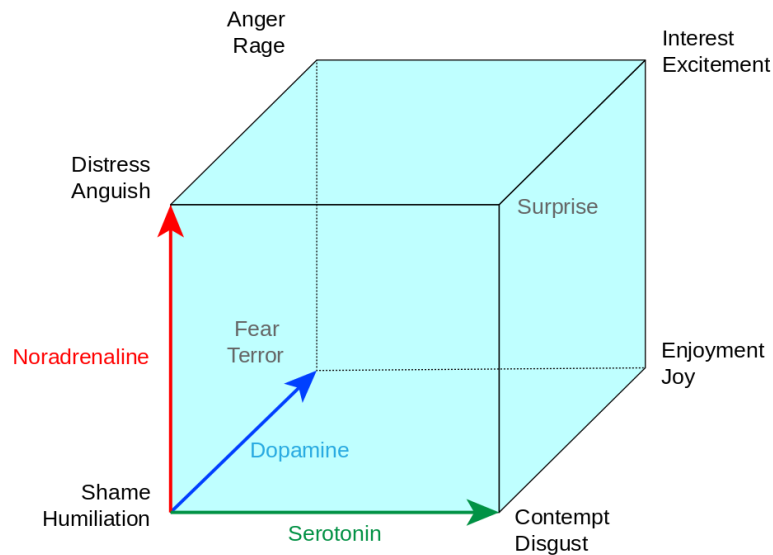


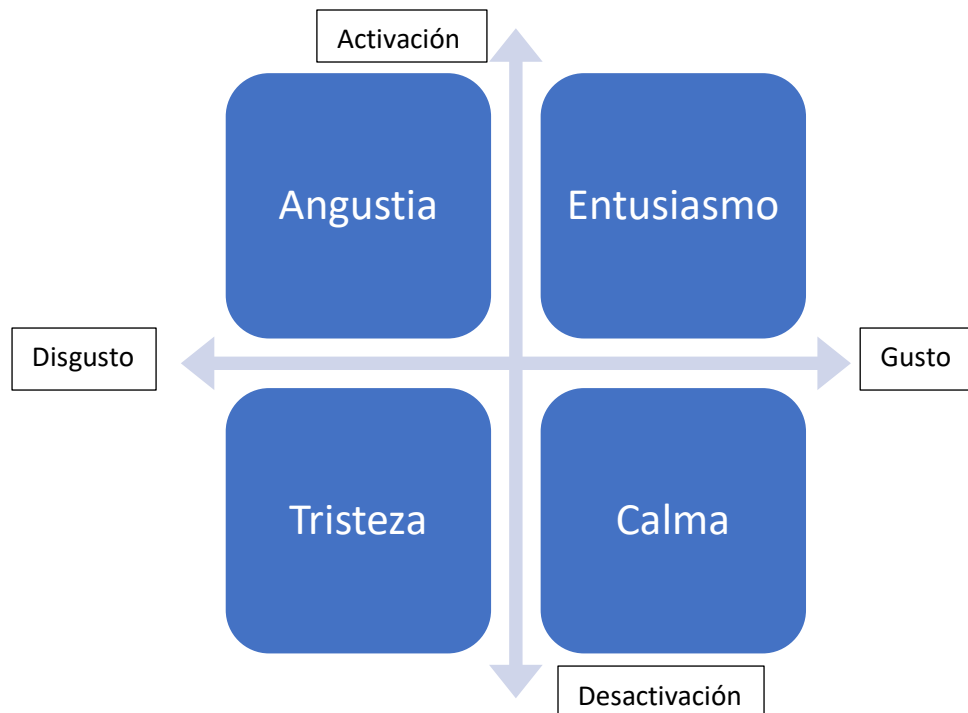
Figura 12 Cubo de Emociones de Lövheim [43]. Cubo de Emociones de Lövheim [43]. Se puede apreciar el origen de los ejes correspondientes a la Noradrenalina, Dopamina y Serotonina en la esquina inferior izquierda del cubo, en donde se muestra que, a medida que los valores de los ejes cambian y se combinan entre sí, generan emociones distintas, por ejemplo, altos valores de Serotonina y Dopamina, pero con bajo valor de Noradrenalina provocan la emoción de alegría.

### 2.2.5.3. Modelo Circumplejo De Russell

Uno de los modelos de emociones más utilizado es el Modelo Circumplejo de Russell, el cual utiliza los componentes Valencia y Aerosal para definir a una emoción. La utilidad de este modelo radica en la facilidad de entendimiento para la conceptualización de emociones por parte de personas no expertas en el ámbito de la psicología, lo cual permite un mayor entendimiento entre los pacientes y los profesionales de la salud. De igual manera, este modelo facilita mucho al momento de medir y valorar la intensidad y tipo de emociones, lo cual es fundamental para la realización de estadísticas [44].

Según este modelo, toda emoción puede ser catalogada por dos componentes principales: el uno que guarda relación con emociones subjetivas agradables o desagradables (Valencia), y el otro que se relaciona con un estado subjetivo de sentirse activado o desactivado (Aerosal) [45], por ejemplo, una persona que ha sufrido la pérdida de sus bienes en un terremoto, puede sentirse deprimida, sin energía ni ganas de realizar ninguna actividad, esto muestra una baja valencia, correspondiente a una emoción desagradable, y a su vez un bajo nivel de aerosal o activación, por otro lado en el mismo evento, una persona puede sentirse pese a la pérdida con muchas ganas de salir adelante, generando un sentimiento positivo frente a la adversidad, esto nos muestra una valencia alta, por el

sentimiento agradable y un alto aerosal, por el nivel de activación y ganas por recuperar lo perdido [44].



*Figura 13 Modelo Circumplejo de Emociones original de Russell. Se muestran las emociones básicas asociadas a cada cuadrante, mismos que se generan a partir de la combinación de los ejes Valencia-Aerosal, los cuales se corresponden con el nivel de gusto o disgusto (valencia) y con el nivel de activación o desactivación que puede tener una emoción (aerosal).*

Para un mejor entendimiento del Modelo Circumplejo de Russell, en la figura 13 se muestran las emociones representadas de acuerdo con la ponencia original de Russell. En ella podemos apreciar las emociones más representativas de los cuatro cuadrantes que se generan al representar los componentes valencia-aerosal en los ejes (x, y) respectivamente.

Así, en el cuadrante superior derecho (alta valencia y alto aerosal) se ubican emociones como la alegría, el entusiasmo. En el cuadrante superior izquierdo (baja valencia y alto aerosal) se ubican emociones como la angustia. En el cuadrante inferior izquierdo (baja valencia y bajo aerosal) se ubican emociones como la tristeza. En el cuadrante inferior derecho (alta valencia y bajo aerosal) se encuentran emociones como la calma.

### **2.2.6. Interfaz Cerebro Computador Afectiva (aBCI)**

Como se ha mencionado, dentro de las BCI, surgen las BCI afectivas (aBCI), las cuales buscan detectar el estado emocional de los usuarios, y usar esa información para que estos interactúen con el computador [1], [2].

#### **2.2.6.1. Categorías de las aBCIs**

Según Daly [1], las aBCI se clasifican en función del grado de control voluntario que el usuario ejerce sobre sus emociones. Dentro de esta clasificación tenemos 2 tipos de aBCI:

1. aBCI Pasivas
2. aBCI Activas

Las aBCI Pasivas detectan el estado emocional del usuario y en base a ello (en forma involuntaria para el usuario) proceden a realizar ajustes en el sistema. Por ejemplo, el cambiar el color de una pantalla en función de la emoción que el usuario tenga, lo cual puede ayudar a regular el estado emocional del mismo [1].

Las aBCI Activas permiten al usuario ejercer de forma voluntaria el control del sistema en base a sus emociones o estados afectivos. Por ejemplo, para elegir entre 2 letras que aparecen en una pantalla, se les puede pedir a los usuarios que imaginen emociones agradables o desagradables, los cuales se corresponden con estados de valencia altos o bajos [1].

#### **2.2.6.2. Ventajas del uso de las aBCI**

Daly [1], propone 3 ventajas principales del uso de las aBCI activas y pasivas:

1. Impulsar el rendimiento de clasificación: Utilizando las emociones del usuario como un medio de comprobación de que un proceso de clasificación -dentro del contexto del aprendizaje automático- fue o no bien realizado, por ejemplo, al percibir emociones de gusto o disgusto en el usuario podemos corroborar si el resultado de la clasificación ha sido el adecuado [1].

2. Comprender las emociones del usuario: Permitiendo una mejor interacción persona-máquina, ayudando a que los sistemas respondan mejor a las necesidades del usuario, por ejemplo, al modular el contenido de un juego o de un entorno virtual de aprendizaje [1].
3. Modular las emociones del usuario: Permite modular las emociones de los usuarios con fines terapéuticos. Para ello se pueden utilizar medidas emocionales que permitan valorar el estado emocional del usuario y en base a ello generar acciones que permitan la regulación emocional del mismo, por ejemplo, cambiando automáticamente la música del entorno [1].

### **2.2.6.3. Investigaciones Relacionadas**

En esta sección se realiza una revisión de investigaciones realizadas en aBCI, para extracción de características y clasificación de emociones.

- M. Murugappan et al. [46], implementaron un procedimiento para la detección de emociones, en el cual, se utiliza el análisis de frecuencia-tiempo de la transformada wavelet (WT) y clasificadores lineales. En este caso, para clasificar las emociones discretas (felicidad, sorpresa, miedo, disgusto y neutral). Los clasificadores lineales utilizados fueron LDA y KNN.
- En otro trabajo realizado por Yasar Dasdemir [31], se utilizó un método no lineal para estudiar la conectividad funcional. Para la investigación realizó a los participantes estímulos evocados a través de audios o videos tomados de manera individual o combinada y empleando las bandas de señales alpha, beta y gamma para el análisis. En los resultados se pudo determinar que la manera más confiable de generar un estímulo es mediante la utilización de videos, independientemente de que estos tengan o no audio, pues los valores no cambiaron al probar estimulaciones de ambas maneras [31].
- En otra investigación, Beatriz García y sus compañeros de proyecto [3], aplicaron tres métricas basadas en entropía: entropía de muestra (SE), SE cuadrática (QSE)

y entropía de distribución (DE) para discernir entre estados emocionales de calma y estrés negativo (también llamado angustia) [3].

La tabla 1 muestra un compendio de los métodos de extracción de características y clasificación de emociones utilizados en algunas investigaciones:

<b>Autores</b>	<b>Año</b>	<b>Pre-proceso</b>	<b>Extracción y selección de características</b>	<b>Clasificación de emociones</b>
Murugappan Murugappan, Nagarajan Ramachandran	2010	Filtro de superficie Laplaceano	Transformada Wavelet. Fuzzy C Means (FCM) and Fuzzy K-Means (FKM)	Linear Discriminant Analysis (LDA) and K Nearest Neighbor (KNN)
You-Yun Lee, Shulan Hsieh	2014	FFT, EEGLAB	Correlación, coherencia y sincronización de fase.	Análisis de discriminante cuadrático
Daniela Iacoviello Andrea Petraccab	2015	Filtro Wavelet	PCA	SVM
Nitin Kumar, Kaushikee Khaund	2015	Blind source separation technique Filtro de paso de banda 4.0-45.0 Hz.	HOSA (Higher Order Spectral Analysis)	LS-SVM ANN
Nitin Kumara, Kaushikee Khaunda	2016	Filtro Butterworth	Análisis Biespectral con HOSA (Higher Order Spectral Analysis)	SVM
G. Mejía, A. Gómez	2016	filtros Butterworth	Trasnformada wavelet estacionaria	QDA
Yong Zhang, Xiaomin Ji	2016	filtros Butterworth	Modo de descomposición empírica (EMD) Entropía de muestra SE	SVM
Beatriz García	2016	Algoritmo basado en Análisis Independiente de Componentes	Entropía de muestra, Entropía Cuadrática, Distribución de Entropía	SVM
Yasar Dasdemir, Esen Yildirim	2017	EEGLAB, MARA, AAR	Valor de Bloqueo de Fase (PLV) con ANOVA para medir significancia.	SVM
Moon Inder Singh, Mandeep Singh	2017	Filtro de superficie Laplaceano	Transformada Wavelet	SVM Polinomial
Bahareh Nakisa, Mohammad Naim Rastgoo	2018	Filtros Butterworth y Notch	Algoritmos ACA, SA, GA, SPO	SVM

*Tabla 1 Métodos de extracción de características y clasificación de emociones. Adaptado y actualizado de [6], con los últimos trabajos respecto al tema.*

### **2.2.7. Aplicaciones de la Computación Afectiva**

La Computación Afectiva tiene múltiples aplicaciones en la actualidad, dentro de ellas podemos citar algunos ejemplos significativos:

El cuidado de la salud es un área de aplicación muy importante de la Computación Afectiva. Al reconocerse las emociones de los pacientes, se ayudaría a prevenir probables sucesos que causen complicaciones a su salud. Uno de los usos de la Computación Afectiva en la medicina radica en la ayuda del manejo emocional en los niños con autismo, ya que en ellos se observa la falta de comunicación de su mundo afectivo, y estas herramientas pueden informar del estado emocional a los pacientes y a los demás, mejorando así la comunicación y la interacción [28].

Las aplicaciones de la Computación Afectiva además se utilizan como herramientas de diagnóstico y tratamiento para la depresión y muchos trastornos relacionados con la ansiedad. Un uso importante es para el diagnóstico y tratamiento del trastorno de estrés postraumático (TEPT), que se desarrolla posteriormente, de que una persona se expone a un evento traumático, como la guerra, un accidente, una muerte sorpresiva de un ser querido, etc. El desarrollo de la Computación Afectiva en el campo de la Psicología ayudará a la comprensión y tratamiento de las enfermedades de origen psicosomático [28].

Como un ejemplo en el campo de la educación, Hernández A. y su equipo de trabajo [47], desarrollaron un sistema de detección de emociones para la recomendación de recursos educativos llamado Emedre. Este sistema fue diseñado para ayudar en las búsquedas de documentos referenciados en base a las emociones de los usuarios. El usuario obtiene una lista de material recomendado, de acuerdo con su búsqueda y estado de ánimo, lo cual corrobora si el material encontrado le agradó. Esto resulta útil en las experiencias de los sucesivos usuarios, que ya dispondrían de material clasificado con antelación.

Otro ejemplo de aplicación de la Computación Afectiva es lo realizado por el equipo de Yue Ding [35], quienes propusieron un enfoque de etiquetado de emociones en tiempo real basado en EEG, al extraer las características entre cerebros de un grupo de participantes mientras observan los mismos videos emocionales. Para ello, se realizaron

análisis de regresión para evaluar la efectividad de las características de amplitud y fase entre cerebros. Esta propuesta puede representar una gran ayuda a empresas como YouTube, en las cuales es de vital importancia el uso de etiquetas y valoraciones de los diferentes videos o artículos, pues en ellas se toma muy en cuenta el aspecto emotivo de los usuarios al momento de recuperar y recomendar este tipo de información.





### 3. ADQUISICIÓN DE DATOS

Se buscaron varias bases de datos EEG enfocadas a la detección de emociones, encontrando que muchas ya no estaban disponibles, pese a ello, se logró conseguir el acceso a 2 sets de datos que se encuentran activos, el primero es DEAP [8] que contiene datos de EEG y datos obtenidos con sensores fisiológicos como ECG, respiración, temperatura de la piel, así como video del rostro de los participantes durante las pruebas y el segundo es SEED [9], [48], [49], [50], [51], que contiene solo señales EEG. En ambos casos fue necesario gestionar el acceso a los datos con los administradores. Para el proyecto se utilizaron los 2 sets de datos.

#### 3.1. El Set de Datos DEAP [8]

The screenshot shows the DEAP dataset website. The header has a dark red background with the text 'DEAPdataset' in white, followed by 'a dataset for emotion analysis using eeg, physiological and video signals'. Navigation links include 'home', 'dataset description' (highlighted), 'download', and 'contact'. The main content area is titled 'dataset summary' and describes the dataset's components. It lists two parts: 1. Online self-assessment ratings and 2. Participant ratings, physiological recordings, and face video. A 'file listing' section follows, showing a table of available files.

**dataset summary**

The DEAP dataset consists of two parts:

1. The ratings from an **online self-assessment** where 120 one-minute extracts of music videos were each rated by 14-16 volunteers based on arousal, valence and dominance.
2. The participant ratings, physiological recordings and face video of an **experiment** where 32 volunteers watched a subset of 40 of the above music videos. EEG and physiological signals were recorded and each participant also rated the videos as above. For 22 participants frontal face video was also recorded.

For a more thorough explanation of the dataset collection and its contents, see [1]

**file listing**

The following files are available (each explained in more detail below):

File name	Format	Part	Contents
<a href="#">Online_ratings</a>	xls, csv, ods spreadsheet	Online self-assessment	All individual ratings from the online self-assessment.
<a href="#">Video_list</a>	xls, csv, ods spreadsheet	Both parts	Names/YouTube links of the music videos used in the online self-assessment and the experiment + stats of the individual ratings from the online self-assessment.

Figura 14 Sitio web del set de datos DEAP [52], [8] . <http://www.eecs.qmul.ac.uk/mmv/datasets/deap/readme.html>

DEAP [8] es un set de datos multimodal (figura 14), para el análisis de estados afectivos humanos. Cuenta con varios tipos de registros fisiológicos, entre ellos, los más relevantes para el estudio fueron los electroencefalográficos (EEG). Los datos fueron tomados de 32 participantes, a quienes se les tomó 40 pruebas con una exposición de un minuto a videos musicales, escogidos de un total de 120 disponibles. Los participantes calificaron cada video en términos de niveles de excitación, valencia, simpatía / antipatía, dominio y

familiaridad. Para 22 de los 32 participantes, también se registró el video frontal del rostro. Dentro de los registros fisiológicos se tiene: respuesta galvánica de la piel, respiración, EOG y EMG. Para cada prueba realizada se especifican los valores de valencia y aerosal (excitación-activación) obtenidos. Estos registros se pueden utilizar, para realizar nuevas investigaciones previo consentimiento de los autores [8].

Cabe destacar que el set de datos consta inicialmente de 2 partes:

- Los resultados de evaluaciones online realizados por 14-16 voluntarios en términos de valencia, aerosal y dominancia respecto de 120 extractos de videos musicales de un minuto de duración.
- Los resultados de las evaluaciones de los 32 participantes del experimento con relación a 40 videos seleccionados de los 120 descritos anteriormente, en términos de valencia, aerosal, dominancia, liking y familiaridad, y los registros de señales fisiológicas y EEG, así como, videos del rostro de 22 de los participantes.

La selección de los 40 videos se realizó al escoger aquellos que tenían los valores de emociones más extremas, por ejemplo: alegría, tristeza, ira, calma.

Con los 40 videos se realizaron los ensayos a los 32 participantes, mismos que se efectuaron en un orden distinto en cada caso, sin embargo, dentro de la base de datos, se organizaron todos en un orden determinado para evitar errores en la utilización de los datos.

Para que los participantes realizaran la evaluación emocional se utilizaron maniqués gráficos denominados SAM [53], en: valencia, aerosal, dominancia y liking.

En la figura 15, se describe la organización de los archivos de datos del set DEAP [8].

File name	Format	Part	Contents
<a href="#">Online_ratings</a>	xls, csv, ods spreadsheet	Online self-assessment	All individual ratings from the online self-assessment.
<a href="#">Video_list</a>	xls, csv, ods spreadsheet	Both parts	Names/YouTube links af the music videos used in the online self-assessment and the experiment + stats of the individual ratings from the online self-assessment.
<a href="#">Participant_ratings</a>	xls, csv, ods spreadsheet	Experiment	All ratings participants gave to the videos during the experiment.
<a href="#">Participant_questionnaire</a>	xls, csv, ods spreadsheet	Experiment	The answers participants gave to the questionnaire before the experiment.
<a href="#">Face_video</a>	Zip file	Experiment	The frontal face video recordings from the experiment for participants 1-22.
<a href="#">Data_original</a>	Zip file	Experiment	The original unprocessed physiological data recordings from the experiment in BioSemi .bdf format
<a href="#">Data_preprocessed</a>	Zip file for Python and Matlab	Experiment	The preprocessed (downsampling, EOG removal, filtering, segmenting etc.) physiological data recordings from the experiment in Matlab and Python(numpy) formats

*Figura 15 Organización de los datos set DEAP [52], [8].  
<http://www.eecs.qmul.ac.uk/mmv/datasets/deap/readme.html>.*

El set de datos consta de los siguientes archivos:

**Online\_ratings.xls:** Contiene las valoraciones de valencia y aerosal realizadas por los participantes para cada prueba en términos de valencia, aerosal, liking, dominancia y familiaridad.

**Video\_list.xls:** Contiene los listados de los 120 videos preliminares con los enlaces a youtube.com de cada video y métricas estadísticas de media, desviación estándar, y cuartiles de las valoraciones en términos de valencia y aerosal realizadas por los participantes.

**Participant\_ratings.xls:** Contiene las valoraciones realizadas a cada prueba por parte de los participantes en términos de valencia, aerosal, dominancia, liking y familiaridad, organizadas por participantes y orden de realización de las pruebas, por lo cual no coincide el orden de los videos en todos los participantes.

**Participant\_questionnaire.xls:** Contiene datos referentes al estado de salud de los participantes y a su nivel de educación.

**Face\_video.zip:** Contiene los videos del rostro de 22 de los 32 participantes durante la realización de las pruebas.

**Data\_original.zip:** Contiene los registros de las señales fisiológicas obtenidas en las pruebas sin procesar en formato .bdf.

**Data\_preprocessed.zip:** Contiene los registros de las señales fisiológicas obtenidas en las pruebas preprocesadas en formato .dat para Python y .mat para Matlab. En el presente estudio se utilizaron los archivos preprocesados .dat para Python.

A los datos preprocesados se les aplicó un filtro pasabanda de 4 a 45 Hz, se removieron los artefactos oculares, se les aplicó un downsamplig a 128 Hz, y fueron divididos en registros de datos de pruebas de 60 segundos más 3 segundos iniciales neutros.

Los datos preprocesados para Python se encuentran almacenados en 32 archivos con el formato “s01.dat”, correspondiendo un archivo de datos por cada participante. Cada archivo .dat consta de 2 arreglos:

**Data:** Con una estructura de 40x40x8064, valores que corresponden al número de pruebas por participante (40), número de canales (40) y datos de la señal almacenada para cada canal (8064). Es importante mencionar que de los 40 canales tan solo los 32 primeros corresponden a EEG y el resto a otras señales fisiológicas almacenadas como ritmo respiratorio, ritmo cardiaco, entre otras.

**Labels:** Con una estructura de 40x4, valores que corresponden al número de pruebas por participante (40) y a las etiquetas (valencia, aerosal, dominancia y liking) correspondientes a cada prueba. Es importante mencionar que las pruebas fueron organizadas en los archivos en un orden idéntico de videos presentados para todos los participantes, para evitar confusiones, dado que, en las pruebas reales el orden de aparición de los videos fue aleatorio.

Dado que toma de registros EEG se realizó en 2 ciudades distintas, el listado de canales por cada ciudad (Twente, Geneva) se muestra en la tabla 2.

Número	Nombre (Twente)	Nombre (Geneva)	Geneva > Twente	Twente > Geneva
1	Fp1	Fp1	1	1
2	AF3	AF3	2	2
3	F7	F3	4	4
4	F3	F7	3	3
5	FC1	FC5	6	6
6	FC5	FC1	5	5
7	T7	C3	8	8
8	C3	T7	7	7
9	CP1	CP5	10	10
10	CP5	CP1	9	9
11	P7	P3	12	12
12	P3	P7	11	11
13	Pz	PO3	16	14
14	PO3	O1	13	15
15	O1	Oz	14	16

16	Oz	Pz	15	13
17	O2	Fp2	32	30
18	PO4	AF4	31	29
19	P4	Fz	29	31
20	P8	F4	30	27
21	CP6	F8	27	28
22	CP2	FC6	28	25
23	C4	FC2	25	26
24	T8	Cz	26	32
25	FC6	C4	22	23
26	FC2	T8	23	24
27	F4	CP6	20	21
28	F8	CP2	21	22
29	AF4	P4	18	19
30	Fp2	P8	17	20
31	Fz	PO4	19	18
32	Cz	O2	24	17

Tabla 2 Distribución de electrodos del set de datos DEAP [8].

### 3.2. El Set de Datos SEED [9], [47], [48], [49], [50].

[bcmi.sjtu.edu.cn/home/seed/index.html](http://bcmi.sjtu.edu.cn/home/seed/index.html)



Figura 16 Sitio web del set de datos SEED [54], [9], [47], [48], [49], [50].  
<http://bcmi.sjtu.edu.cn/home/seed/index.html>

El set de datos SEED [9], consta de registros EEG y videos faciales obtenidos en experimentos realizados a 15 sujetos (figura 16). Los experimentos consistían en evocar estímulos a los participantes mediante la presentación de videos de origen chino, de cuatro

minutos de duración. El tipo de emociones evocadas por los videos fueron clasificadas en los rangos: positivas, neutrales y negativas. Luego de observar cada video, los participantes debían realizar un cuestionario para informar respecto de sus estados afectivos.

Con la finalidad de realizar estudios sobre similitudes entre las señales durante las sesiones e individuos, a cada participante se le realizaron 3 sesiones, mismas que fueron llevadas a cabo en diferentes días con al menos una semana de diferencia. Cada sesión consta de 15 experimentos, dando un total de 45 experimentos por participante. En cada sesión se utilizaron 5 videos asociados a emociones positivas, 5 a emociones negativas y 5 neutrales, para que el experimento sea balanceado.

Para el registro de los datos EEG se utilizó una frecuencia de muestreo de 1000Hz, y se utilizaron 62 canales según el sistema internacional 10-20.

Los datos que se permiten descargar del set de datos son de señales preprocesadas, en la cual se eliminaron los artefactos de manera manual, se utilizó un filtro pasabanda entre 0.3 Hz y 50 Hz y se realizó un downsampling a 200Hz.

El set consta de 45 archivos con los registros de las señales EEG, nominados con el nombre del participante y la fecha del experimento, por ejemplo: “zhujiayi\_20130709.mat”. Adicionalmente existe un archivo denominado “labels.mat”, el cual contiene las etiquetas de las emociones asignadas a cada experimento.

Los archivos .mat de cada participante consta de un arreglo con una estructura de 15x62x48000, correspondientes al número de pruebas realizadas (15), número de canales (62) y datos de la señal almacenada para cada canal (48000).

El listado de canales EEG de acuerdo con el sistema internacional 10-20 se muestra en la tabla 3.

Nº Canal	Nombre	Nº Canal	Nombre	Nº Canal	Nombre
1	FP1	22	FC6	43	P5
2	FPZ	23	FT8	44	P3
3	FP2	24	T7	45	P1
4	AF3	25	C5	46	PZ
5	AF4	26	C3	47	P2
6	F7	27	C1	48	P4
7	F5	28	CZ	49	P6
8	F3	29	C2	50	P8

9	F1	30	C4	51	PO7
10	FZ	31	C6	52	PO5
11	F2	32	T8	53	PO3
12	F4	33	TP7	54	POZ
13	F6	34	CP5	55	PO4
14	F8	35	CP3	56	PO6
15	FT7	36	CP1	57	PO8
16	FC5	37	CPZ	58	CB1
17	FC3	38	CP2	59	O1
18	FC1	39	CP4	60	OZ
19	FCZ	40	CP6	61	O2
20	FC2	41	TP8	62	CB2
21	FC4	42	P7		

*Tabla 3 Listado de canales del set de datos SEED [9].*





## 4. METODOLOGÍA

En este capítulo se expone en forma detallada la aplicación de los métodos para la extracción de características y para la clasificación de emociones de las señales EEG de los set de datos SEED [9] y DEAP [8].


Es importante mencionar que el estudio se basa en su totalidad en el análisis de los datos de la base SEED [9], incluyendo tan solo dos pruebas sobre el set de datos DEAP [8], como ejemplos adicionales. Esto debido a la complejidad del set de datos DEAP [8], pues no solo cuenta con señales EEG, sino también con otros tipos de señales fisiológicas, y un sistema de etiquetado basado en métricas de valencia y aerosal, por lo cual resulta más complicado de trabajar que el set de datos SEED [9], además, de acuerdo a lo especificado en el artículo de García et al.[3], se menciona que el trabajo con el set DEAP [8], en anteriores investigaciones ha resultado en niveles de acierto relativamente bajos, recomendando en ese mismo artículo, la realización de estudios más detallados al respecto, debido a su complejidad, lo cual, queda fuera del alcance de este estudio, por ello, se ha utilizado el mencionado set de datos, básicamente para poner a prueba los métodos desarrollados en el presente TFM.

### 4.1. Obtención de Ondas Cerebrales

De acuerdo a lo explicado en el capítulo anterior, los registros EEG proporcionados por el set de datos SEED [9], están filtrados, dejando los datos entre las frecuencias comprendidas entre los 0.5 Hz y 50 Hz. De igual manera los datos del set DEAP [8], están filtrados con un filtro pasabanda comprendido entre los 4 Hz y 45 Hz.

Ambos sets de datos están organizados por archivos correspondientes a los participantes, dentro de los cuales se encuentran los experimentos, ensayos o trials, y para cada uno de ellos le corresponden un número de canales específicos (AF3, AF4, etc.). En el caso del set SEED [9], cada archivo tiene una estructura de 15x62x48000, mientras que para el set DEAP [8], la estructura es de 40x32x8064, correspondientes al número de experimentos por cada participante, número de canales y longitud de la señal respectivamente, de acuerdo a lo especificado en la sección 3 para cada set de datos.

Según del review de Alarcao et al. [2], en la mayoría de las investigaciones previas sobre el reconocimiento de emociones basadas en EEG, se utilizaron los ritmos cerebrales como base de los estudios, por lo cual, se decidió tomarlos también como base para las pruebas realizadas en el presente TFM, así, se obtuvieron previamente las señales theta, alpha, beta y gamma de todos los canales. Se decidió dejar de lado en este estudio a las ondas Delta, dado que los datos del set de datos DEAP [8], de acuerdo a lo especificado en líneas anteriores, se encuentran entre las frecuencias 4 y 45 Hz, por lo cual no es posible obtener estas ondas cuyo rango de frecuencias se ubica entre 1 y 4 Hz, de acuerdo a lo descrito previamente en la sección 2.2.3.1. Para el efecto, se aplicó el filtro butterworth mediante el proceso explicado por C. Jaganathan en [55], el cual se resume en la figura 17.




*Figura 17 Proceso para la extracción de ondas cerebrales: se inicia con la obtención de las señales EEG, seguido de la especificación del rango de frecuencias para cada tipo de onda y el tiempo de muestreo, luego se aplica el filtro Butterworth, para finalmente obtener los distintos tipos de ondas delta, theta, alpha, beta y gamma.*

El filtro Butterworth [56] es uno de los filtros más populares utilizados para el trabajo con señales EEG. Este filtro produce una respuesta de frecuencia lo más plana posible. Una virtud de este filtro es que, aun con un número de orden mayor, la respuesta conserva su forma, sin embargo, a diferencia de otros filtros, se hace necesario trabajar con un número de orden más alto, para obtener similares resultados [57], [58].

Para obtener los ritmos cerebrales desde las señales del set de datos SEED [9], se procedió a utilizar el filtro Butterworth de Python con orden 9, para que las señales se ubiquen correctamente en los rangos de frecuencias deseados.

En la figura 18 se puede apreciar la señal de las ondas alpha, correspondiente al análisis de frecuencia de la señal del canal 1 del experimento 1 del archivo

“zhujiayi\_20130709.mat”, del set de datos SEED [9], la cual ha sido filtrada con un filtro Butterworth entre 8 y 14 Hz con orden 9.



*Figura 18 Ondas alpha.*

Los rangos de frecuencias utilizados en el filtro Butterworth para cada ritmo cerebral, de acuerdo con lo establecido en el artículo de Wei-Long Zhen [9] fueron:

Theta: filtro pasabanda entre las frecuencias 4 y 8 Hz. (orden=9)

Alpha: filtro pasabanda entre las frecuencias 8 a 14 Hz. (orden=9)

Beta: filtro pasabanda entre las frecuencias 14 y 31 Hz. (orden=9)

Gamma: filtro paso alto con una frecuencia inferior de 31 Hz. (orden=9)

En el caso del set de datos DEAP [8], se utilizaron prácticamente las mismas frecuencias, pero diferente número de orden para el filtrado, de acuerdo a lo descrito en [8].

Theta: filtro pasabanda entre las frecuencias 4 y 8 Hz. (orden=8)

Alpha: filtro pasabanda entre las frecuencias 8 a 14 Hz. (orden=9)

Beta: filtro pasabanda entre las frecuencias 14 y 30 Hz. (orden=15)

Gamma: filtro paso alto con una frecuencia inferior de 30 Hz. (orden=25)

Para realizar una sola vez el procesamiento de las señales originales y mejorar el tiempo de cómputo, se procedió a guardar los datos de las ondas delta, theta, alpha, beta y gamma en archivos binarios .dat, con nombres similares a los archivos de los sets de datos SEED [9] y DEAP[8] respectivamente. De este modo se evitó repetir por cada prueba el tiempo del filtrado. Para la escritura y apertura de los archivos se utilizó la librería Pickle [59], de Python, dado que tiene funciones, que permiten realizar estas acciones con facilidad.

La estructura en que se guardan los datos en cada archivo es (15x62x5x47001) para el set de datos SEED [9], y (40x32x5x7680) para el set de datos DEAP [8], correspondientes al número de experimentos, número de canales, número de ritmos (delta, theta, alpha, beta y gamma) y a la longitud de la señal, respectivamente. Hay que mencionar que se guardaron los datos del ritmo delta pese a que no se los utilizó para los cálculos del presente trabajo, para su posible utilización en estudios posteriores, sobre todo en el caso del set de datos SEED [9].

## **4.2. Métodos de Extracción de Características**

En esta etapa se buscó crear una representación significativa de la señal, que permita aumentar el rendimiento en la fase de clasificación, mediante la extracción de diversas características de la señal y su posterior combinación en supervectores de características (consultar sección 4.3).

Se extrajeron varios tipos de características para realizar pruebas de rendimiento. Para ello se analizaron comparativamente los niveles de acierto obtenidos por cada característica y se eligieron las que tuvieron un mayor acierto a nivel individual, para construir en base a ellas los supervectores (consultar sección 4.3).

Para la utilización de un vector de características en un clasificador, se procedió a organizar en un mismo vector, una a continuación de otra, las características de los canales correspondientes a un mismo experimento. Por ejemplo: Si la característica es la media aritmética de las señales, el vector de características tendrá una dimensión de  $1 \times 4 \times 62 = 248$  elementos. Esto porque tenemos una característica por cada uno de los 4 ritmos theta, alpha, beta y gamma, y a su vez tenemos 62 canales en el caso del set de datos SEED [9]. En el caso del set de datos DEAP [8], solo cambiaría el número de canales a 32, por lo cual tendríamos  $1 \times 4 \times 32 = 128$  elementos.

Para realizar pruebas preliminares (únicamente con el set de datos SEED [9]), se procedió a utilizar características de Entropía Diferencial (DE) [49], [9], y Densidad Espectral de Potencia con Media Móvil (PSD) [48], [9], extraídas por los autores del propio set de datos SEED [9], las cuales vienen incluidas en el set. Las mencionadas características se

explican con mayor detalle en las secciones 4.2.1.1 y 4.2.1.2 respectivamente. En estos estudios preliminares, no se utilizó la validación cruzada, debido a que en los artículos referentes al mencionado set de datos [48], [9], no se especifica su utilización.

Se utilizó la Entropía Diferencial para realizar esta prueba, dado que es la característica con la que los autores obtuvieron el valor más alto de acierto, llegando a obtener un 86.08% con los datos de la base SEED [9]. Esta característica, al igual que la PSD se extraen directamente de cada canal de manera individual.

Posteriormente se procedió a realizar pruebas con validación cruzada con los sets de datos SEED [9] y DEAP [8], utilizando acuerdo a la clasificación mencionada por varios autores [45], [5], [46], características en el dominio del tiempo, de la frecuencia y de tiempo-frecuencia. A continuación, se describen las características que fueron utilizadas para realizar las pruebas en las siguientes secciones.

#### **4.2.1. Dominio del Tiempo**

En esta sección se explican las características de: Entropía Diferencial [48], [9], Métricas Estadísticas Simples [5], [2], Parámetros HJORTH [60], [61], Cruces por Cero [62], [63], Análisis de Fluctuación Descendente [64], [61], y Dimensión Fractal [65], [66], [67].

##### **4.2.1.1. Entropía Diferencial (DE)**

La entropía diferencial es la medida de la entropía de una variable aleatoria continua, por lo cual, es utilizada para medir la complejidad de ese tipo de variables (ecuación 4.1). La entropía diferencial guarda relación con la longitud mínima de descripción [49], [48].

$$h(X) = - \int_x f(x) \cdot \log(f(x)) \partial x \quad (4.1)$$

Según Li-Chen Shi et al. [49], se pudo determinar que aunque las señales EEG no se ajustan a una distribución específica, estas sí se sujetan a una distribución Gaussiana en una serie de subbandas, luego de haberlas aplicado un filtro pasabanda entre 2 y 44 Hz, por lo cual, para obtener la entropía diferencial es factible aplicar la ecuación 4.2.

$$h(X) = \frac{1}{2} \cdot \log(2\pi e \sigma^2) \quad (4.2)$$

Donde,  $\sigma^2$  representa la varianza de la señal analizada, y  $e$  el número de Euler o constante de Napier.

En el caso de la Entropía Diferencial solo se utilizaron los datos pre calculados por los autores del set de datos SEED [9], para la realización de pruebas preliminares, por lo cual no se utilizó esta característica para las pruebas con el set de datos DEAP [8].

#### 4.2.1.2. Métricas Estadísticas Simples

Se procedió a realizar pruebas extrayendo como características de las señales la media aritmética, el valor máximo, el valor mínimo, la desviación típica o estándar, el sesgo o asimetría y la curtosis.

- Media: Se define como la sumatoria de todos los valores de la señal analizada, dividido para el número de valores que componen la señal. Se la puede entender como el centro geométrico o “centro de gravedad” de la señal analizada [68].
- Valor Máximo: Se realiza la búsqueda del elemento con el valor más alto de la señal analizada.
- Valor Mínimo: Se realiza la búsqueda del elemento con el valor más pequeño de la señal analizada.
- Desviación Típica o Estándar: En una medida de variabilidad que se define como el promedio de las desviaciones de los elementos de la señal analizada respecto a su media [68].
- Sesgo o Asimetría: Informa sobre el grado de asimetría de la distribución de datos de la señal analizada. Es una medida mediante la cual se puede identificar el modo en que los datos de la señal tienden a agruparse de acuerdo con la frecuencia con que se encuentren en esa distribución [68].

Al realizar estos cálculos es factible determinar cuan simétrica es la distribución de datos de la señal analizada.

Existen varias maneras de calcular el sesgo, entre ellas, el coeficiente de asimetría de Bowley-Yule (ecuación 4.3).

$$A_{BY} = \frac{Q_3 + Q_1 - 2M_e}{Q_3 - Q_1} \quad (4.3)$$

Donde, los valores de Q representan los cuartiles 1, 2 y 3 respectivamente, y Me la mediana.

En el caso de el sesgo sea positivo o sesgada a la derecha, la cola de la distribución de los datos de la señal se encontrará hacia la derecha y en el caso de que sea negativo, la cola de la distribución de los datos de la señal se encontrará hacia la izquierda. Si el valor del sesgo es cero, quiere decir que la distribución de los datos de la señal analizada es simétrica, es decir similar a una campana de Gauss.

- Curtosis: Informa sobre el grado de homogeneidad de la distribución de datos de la señal. La curtosis representa el grado de apuntamiento que tiene dicha distribución de datos. Mediante la curtosis se puede saber la proporción de la varianza explicada por la combinación de outliers respecto a la media en contraposición con datos en posiciones más centrales [68].

Una distribución de datos puede ser leptocúrtica si la figura es más apuntada que una distribución normal, platicúrtica si es menos apuntada que una distribución normal o mesocúrtica si la curva tiene un grado de apuntamiento similar a una distribución normal, es decir similar a una campana de Gauss.

Existen varias maneras de calcular la curtosis, siendo más extendido el uso del cuarto momento estadístico adimensional respecto a la media (ecuación 4.4).

$$\alpha^4 = \frac{M^4}{\sigma^4} \quad (4.4)$$

Donde,  $M^4$  representa el cuarto momento estadístico dimensional y  $\sigma^4$  representa la desviación típica o estándar elevada a la cuarta potencia.

Para el cálculo de las métricas estadísticas se utilizó las librerías numpy y stats, de las cuales se utilizó las siguientes funciones:

Media: `np.mean(vector)`

Valor máximo: `np.max(vector)`  
 Valor mínimo: `np.min(vector)`  
 Desviación Típica: `np.std(vector)`  
 Sesgo o Asimetría: `stats.skew(vector)`  
 Curtosis: `stats.kurtosis(vector)`

En todos los casos, al ser el resultado de las funciones un valor escalar, los vectores resultantes tuvieron una longitud igual a  $(1 \times 4 \times 62) = 248$ , correspondientes a la medida calculada por 4 ritmos cerebrales (theta, alpha, beta y gamma) y por 62 canales. En el caso de la base DEAP [8], la longitud sería  $(1 \times 4 \times 32) = 128$  al contar esta con 32 canales.

#### 4.2.1.3. Parámetros HJORTH

Parámetros Hjorth: Se los define como métricas de propiedades estadísticas de señales que se encuentran en el dominio del tiempo, por lo cual, a estas características se las ubica también dentro de esta clasificación, pese a que sus resultados pueden interpretarse en el dominio de la frecuencia [60]. Son tres: Actividad, Movilidad y Complejidad.

- Actividad: Representa la potencia de la señal [69]. Se calcula con la ecuación 4.5.

$$Ax = \frac{\sum_{t=1}^T (x(t) - \mu)^2}{T} \quad (4.5)$$

Donde,  $x(t)$  representa los datos de la señal en el tiempo,  $\mu$  representa la media de la señal y  $T$  representa el número total de elementos de la señal.

- Movilidad: Nos informa sobre la proporción de desviación estándar del espectro de potencia [69]. Se calcula con la ecuación 4.6.

$$Mx = \sqrt{\frac{var(\dot{x}(t))}{var(x(t))}} \quad (4.6)$$

Donde,  $var(\dot{x}(t))$  representa la varianza de la primera derivada de la señal analizada y  $var(x(t))$  la varianza de la señal analizada.



- Complejidad: Analiza la similitud de la señal al compararla con una sinusoidal pura, cuyo resultado tiende a 1 cuando la similitud es mayor [69]. Se calcula con la ecuación 4.7.

$$Cx = \frac{M(\dot{x}(t))}{M(x(t))} \quad (4.7)$$

Donde,  $M(\dot{x}(t))$  representa la movilidad de la primera derivada de la señal analizada y  $M(x(t))$  la movilidad de la señal analizada.

En el presente estudio se utilizaron como características únicamente los parámetros HJORTH movilidad y HJORTH complejidad, debido a que el parámetro HJORTH actividad representa la varianza de la señal analizada, por lo cual sería redundante con la característica obtenida a partir de la métrica desviación típica o estándar descrita en la sección 4.2.1.2. Para el cálculo de los mencionados parámetros, se utilizó el módulo open source de Python PyEEG [61], el cual se enfoca en la extracción de características de señales EEG y MEG. Este módulo ha sido probado en investigaciones previas sobre Epilepsia basadas en señales EEG [61].

De igual manera que en el caso de las métricas estadísticas, al ser el resultado de las funciones un valor escalar, los vectores resultantes tuvieron una longitud igual a  $(1 \times 4 \times 62) = 248$ , correspondientes a la medida calculada por 4 ritmos cerebrales (theta, alpha, beta y gamma) y por 62 canales. En el caso de la base DEAP [8], la longitud sería  $(1 \times 4 \times 32) = 128$  al contar esta con 32 canales.

#### 4.2.1.4. Cruces por Cero

Este método busca aquellos puntos de la señal que tengan un valor de cero o cercano a cero, y almacenar los valores de las posiciones en el tiempo de estos en un vector [62]. Adicionalmente, se calculó la media aritmética de los datos almacenados en el vector, así como también su desviación típica o estándar.

El rango de datos válidos se los ubicó en primera instancia en el valor de cero exacto, lo cual generaba resultados erróneos, pues en muchos casos no existían ceros exactos en la señal, sino solo valores cercanos a cero. Luego se procedió a ampliar este rango y ubicarlo entre -0.1 y 0.1. Pese a ello, en algunas señales no se encontraba ningún cruce, por lo cual, para evitar el error, se procedió a ubicar controles en el algoritmo para que en caso de que el vector que guardaba las posiciones de cruces por ceros estuviera vacío, no se realizara el cálculo de la media aritmética y de la desviación estándar, ubicando en el lugar del resultado de tales cálculos el valor de cero.

Se utilizó el número de cruces por ceros de las señales, así como su promedio y desviación estándar como características. Por tanto, se procedió a guardar 3 valores escalares por cada uno de los cuatro ritmos cerebrales, con lo cual se conseguía un vector de 3 características por 4 señales y por 62 canales ( $3 \times 4 \times 62 = 744$ ), con una longitud final del vector de 744 elementos para cada ensayo o trial.

#### **4.2.1.5. Análisis de Fluctuación Descendente (del inglés FDA)**

En una medida de la autoafinidad estadística de una señal. Se la define como una manera eficiente y simple para investigar correlaciones a largo plazo en series temporales no estacionarias, por lo que su aplicación es recomendada en señales dinámicas no estacionarias, por lo que es aplicable a señales EEG [64].

La fórmula para el cálculo de la FDA se puede observar en la ecuación 4.8.

$$F(n) = \sqrt{\frac{1}{N} \sum_{t=1}^N (X_t - Y_t)^2} \quad (4.8)$$

Donde,  $N$  representa el número de elementos de la ventana analizada,  $X_t$  los valores de los datos de la señal analizada,  $F$  es la señal de salida y  $n$  representa el número de ventana que se está analizando.

Para el cálculo de la característica FDA, se utilizó el módulo open source de Python PyEEG [61].

En forma similar que en los parámetros HJORTH, al ser el resultado de las funciones un valor escalar, los vectores resultantes tuvieron una longitud igual a  $(1 \times 4 \times 62) = 248$ , correspondientes a la medida calculada por 4 ritmos cerebrales (theta, alpha, beta y gamma) y por 62 canales. En el caso de la base DEAP [8], la longitud sería  $(1 \times 4 \times 32) = 128$  al contar esta con 32 canales.

#### 4.2.1.6. Dimensión Fractal

La fractalidad hace referencia formas o fluctuaciones en el tiempo que guardan auto-similaridades. Como métrica, la dimensión fractal nos indica el grado de complejidad de la señal analizada. Existen varios métodos para calcular la dimensión fractal, dentro de los cuales, por su utilidad en el análisis de señales EEG en investigaciones previas, en este estudio se utilizaron los métodos de Higuchi y Petrosian [70], [65], [67], [71].

La Dimensión Fractal de Higuchi (del inglés HFD), es un método veloz, que permite obtener valores de la complejidad de una serie de datos, más acertados que otros métodos, conservando estas características aun en casos donde la longitud de los vectores de datos es pequeña [67], [71].

La Dimensión Fractal de Petrosian (del inglés PFD), al igual que el método de Higuchi, calcula de forma rápida la dimensión fractal, debido a que transforma los datos de la señal analizada a datos binarios [65]. La PFD se calcula mediante la ecuación 4.9.

$$FD_{Petrosian} = \frac{\log_{10} n}{\log_{10} n + \log_{10} \left( \frac{n}{n + 0.4N_{\Delta}} \right)} \quad (4.9)$$

Donde,  $n$  es la longitud de la señal analizada y  $N_{\Delta}$  es el número de cambios de signo en la secuencia binaria.

Para el cálculo de las característica HFD y PFD, se utilizó el módulo open source de Python PyEEG [61].

Al ser el resultado de las funciones un valor escalar, los vectores resultantes tuvieron una longitud igual a  $(1 \times 4 \times 62) = 248$ , correspondientes a la medida calculada por 4 ritmos

cerebrales (theta, alpha, beta y gamma) y por 62 canales. En el caso de la base DEAP [8], la longitud sería  $(1 \times 4 \times 32) = 128$  al contar esta con 32 canales.

### 4.2.2. Dominio de la Frecuencia

En esta sección se explica únicamente la característica de Densidad Espectral de Potencia [4], [5], pues no se utilizaron otras características en el dominio de la frecuencia para este estudio.

#### 4.2.2.1. Densidad Espectral De Potencia (PSD)

La Densidad Espectral de Potencia (PSD) es una de las características dentro del dominio de la frecuencia que más se utiliza para el reconocimiento de emociones basadas en EEG [6]. Describe la potencia de la señal analizada en función de la frecuencia, informándonos sobre el nivel de dispersión de la potencia de la señal [4], [72]. Se basa en la Transformada Rápida de Fourier (FFT), que es un algoritmo para calcular la Transformada de Fourier Discreta y su inversa. Mediante esta transformada se puede pasar los datos del dominio del tiempo al dominio de la frecuencia y a su vez realizar la operación inversa [4], [73].

Para las pruebas iniciales sin validación cruzada se utilizó los valores de PSD incluidos en el set de datos SEED [9], pero para las pruebas posteriores con validación cruzada se calculó la PSD de las ondas theta, alpha, beta y gamma de cada canal, utilizando la función Welch de Python, con frecuencia de muestreo de 200 Hz y con un tamaño de ventana de 512.

Luego de obtener la PSD, se aplicó el filtro Media Móvil, para suavizar la señal.

El filtro media móvil se calcula dividiendo a la señal en ventanas de  $N$  elementos, de los cuales se calcula la media aritmética [74]. Se calcula mediante la ecuación 4.10.

$$Y_i = \frac{1}{N} \cdot \sum_{k=0}^{N-1} X_{i-k} \quad (4.10)$$

Donde,  $N$  representa el número de elementos de la ventana,  $X$  es la señal analizada,  $Y$  es la señal de salida e  $i$  representa el número de ventana que se está analizando.

El objetivo de este filtro es eliminar parte del ruido de alta frecuencia de la señal. El tamaño de la ventana es importante debido a que, mientras más grande es la ventana, mayor es el suavizado que se obtiene en la señal, sin embargo, un tamaño muy grande puede incurrir en la pérdida de información valiosa de la señal, además de generar un desfase entre la señal suavizada y la señal inicial [74], [75].

Como resultado del proceso anterior se obtuvo un vector, del cual se calculó la media aritmética y la varianza de cada una de las ondas componentes de cada canal, para utilizarlas como características.

### **4.2.3. Dominio Tiempo-Frecuencia**

En esta sección se explica únicamente la característica Wavelets [63], [76], [46], pues no se utilizaron otras características en el dominio tiempo-frecuencia para este estudio.

#### **4.2.3.1 Wavelets**

La Transformada Wavelet es una herramienta matemática con variadas aplicaciones en el campo del procesamiento de señales, tales como compresión de señales, detección de autosimilitudes, etc. Es útil en el tratamiento de señales no estacionarias.

Transforma la señal a una representación respecto de versiones dilatadas y trasladadas de una óndula madre. Se diferencia con la Transformada de Fourier en que esta presenta la información solo en el dominio de la frecuencia, mientras que la Transformada Wavelet presenta la información tanto en el dominio del tiempo como del de frecuencia de manera prácticamente simultánea [77].

Dentro de las familias de Wavelets madre, tenemos las Daubechies, han sido utilizadas en investigaciones anteriores en el tratamiento de señales EEG, y de manera más específica en el reconocimiento de emociones basadas en EEG, por ejemplo, en el estudio realizado por Mejía et al [63], referente al uso de las Wavelets en la clasificación de emociones, se utilizaron las Wavelets Daubechies 1 (db1), por lo cual se decidió tomar este tipo de Wavelets para la realización de este estudio.

Para el cálculo de los vectores de coeficientes de las Wavelets, se utilizó el toolbox open source para Python PyWavelets, el cual permite calcular varios tipos de Wavelets.

Luego de tener calculados los coeficientes, se procedió a tomar como valor estadístico la desviación estándar de cada uno de los 2 vectores resultantes de la aplicación de las Wavelets. Por lo cual, el vector de características tiene una longitud de  $(2 \times 4 \times 62) = 496$  elementos. En las pruebas con el set de datos DEAP [8], no se utilizó esta característica.

#### 4.2.4. Medidas de las Emociones: Valencia y Aerosal

De acuerdo con lo establecido en la sección 2.2.5.3, podemos decir que la valencia representa la medida de gusto o disgusto que se puede tener por algo. En este caso las pruebas consistían en videos, por lo cual la valencia representará la medida en que ese video gustó o no. El aerosal nos muestra la medida de lo activa o inactiva que puede resultar una emoción, por ejemplo, tanto la calma como la alegría tienen valencia elevada, pero se diferencian porque la alegría tiene el aerosal alto, mientras que la calma tiene aerosal bajo, de acuerdo al modelo circunflejo de Russell [45].

Hay varias fórmulas propuestas para el cálculo de la valencia, y del aerosal, las cuales fueron probadas por Al-Nafjan [4], señalando a las expuestas en las ecuaciones 4.11, 4.12 y 4.13 como las de mayor exactitud.

$$\text{Valencia} = \frac{\alpha(F4)}{\beta(F4)} - \frac{\alpha(F3)}{\beta(F3)} \quad (4.11)$$

$$\text{Valencia} = \alpha(F4) - \beta(F3) \quad (4.12)$$

$$\text{Aerosal} = np. \log_2 \left( \frac{\text{front}_{\beta}}{\text{front}_{\alpha}} \right) \quad (4.13)$$

Para el análisis del set de datos SEED [9], se utilizó como característica únicamente la valencia, debido a que las emociones del set están clasificadas en positivas, negativas y neutras, por lo cual, el componente Aerosal no toma parte de la misma al no existir

diferenciación en el nivel de activación de las emociones, tal como se lo ha explicado en el ejemplo de la alegría y la calma [45].

En el caso del set de datos DEAP [8], se utilizó también solo la valencia, dado que el análisis que se realizó sobre la misma fue únicamente en el eje de emociones positivas o negativas, lo cual equivale a trabajar en el eje de la valencia.

Para ambos sets de datos, se utilizaron las dos fórmulas de valencia propuestas, por lo cual, se procedió a calcular la media aritmética de las señales alpha y beta de los canales F3 y F4 para utilizar estos valores en las fórmulas correspondientes y obtener los dos resultados de valencia. Estos resultados se incluyen en un vector que tiene una longitud de 2 elementos, pues, a diferencia del resto de características, ya no se guarda la información por canal (solo se utilizan 2 canales específicos: F3 y F4), sino que se obtiene un valor de valencia para cada experimento y por cada fórmula.

Por tanto, la estructura para almacenar la valencia en el archivo .dat es una matriz de (NxM) filas, en donde N representa el número de participantes de los experimentos y M el número de experimentos, ensayos o trials realizados a estos y 2 columnas.

### **4.3. Combinación de Características (SUPERVECTORES)**

Uno de los objetivos de este trabajo fue encontrar la combinación óptima de diferentes características en un supervector, al probar si esas combinaciones permiten mejorar el nivel de acierto en el reconocimiento de emociones.

Para ello, luego de realizar las pruebas con las características de manera individual, se procedió a elaborar una tabla comparativa con los resultados de los experimentos (detallada al final de la sección 5.1.2.1.), para en base a ella proceder a elegir el 50% de características que tengan mayor nivel de acierto y construir los supervectores.

De manera preliminar se procedió a implementar un supervector, denominado “Supervector 0”, mediante la combinación de las 2 características mencionadas en la parte superior (DE y PSD), las cuales fueron pre calculadas y extraídas directamente del set de datos SEED [9], y evaluar así su nivel de acierto en forma conjunta. El desempeño de este Supervector se probó sin la realización de validación cruzada.

Posteriormente se construyeron 8 supervectores diferentes (Tabla 4), los cuales se muestran en detalle en la sección 5 correspondiente a resultados. En el caso del supervector 8, se le procedió a adicionar la Valencia al supervector con mayor nivel de acierto. Esto debido a que la Valencia es una característica que guarda relación directa con el reconocimiento de emociones, por lo cual, era preciso probarla, aun si el nivel de acierto de esta resultaba relativamente bajo en las pruebas individuales.

Para unir las diferentes características, se procedió a desarrollar un algoritmo que luego de recibir como parámetro los nombres de los archivos que contienen las características a formar parte del supervector, obtiene los datos de estos archivos y los organiza en una estructura matricial de (NxM) filas, en donde N representa el número de participantes de los experimentos y M el número de experimentos, ensayos o trials realizados a estos, y columnas igual al número de características asignadas al supervector multiplicadas por 4 (ritmos cerebrales) y por el número de canales.

Supervector	Set de Datos	Características Combinadas
0	SEED	Entropía Diferencial (DE) y PSD con Media Móvil
1	SEED	HJORTH Complejidad, HJORTH Movilidad, HFD, DFA
2	SEED	HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, Desviación Típica
3	SEED	HJORTH Complejidad, HJORTH Movilidad, DFA
4	SEED	HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD
5	SEED	HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Cruces por Ceros
6	SEED	HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Cruces por Cero
7	SEED	HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Wavelet db1, Cruces por Ceros
8	SEED	HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Cruces por Ceros, Valencia
DEAP 1	DEAP	HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Cruces por Ceros



DEAP 2	DEAP	HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Cruces por Ceros, Valencia
--------	------	---

*Tabla 4 Combinaciones de características por Supervector y Set de Datos.*

## 4.4. Métodos para Clasificación de Emociones

Existen múltiples métodos de clasificación de emociones, dentro de los cuales se encuentran: las máquinas de vectores de soporte, árboles de decisión, redes neuronales artificiales, entre otros.

- **Redes Neuronales Artificiales:** Las redes neuronales artificiales actúan en forma similar a las redes neuronales biológicas. Las neuronas están interconectadas entre sí y trabajan en conjunto. El objetivo es que, dado un problema, se busque la mejor configuración (modificando los pesos) de la red para que este puede resolverse. Este proceso se llama entrenamiento de la red, luego de lo cual ya puede ser utilizada para hacer predicciones [78], [79].
- **Máquinas de Vectores de Soporte (SVM):** Es uno de los algoritmos de aprendizaje supervisado más utilizados. Este algoritmo se basa en la generación de un hiperplano que hace las veces de frontera de decisión para separar clases. La característica fundamental de los SVM es que el margen de separación de los datos llega a ser lo más amplio posible. Los SVM utilizan métodos kernel, los cuales pueden ser de varios tipos, entre ellos tenemos: lineal, polinómico, gaussiano, entre otros. [78], [79].
- **Árboles de Decisión:** Están constituidos por algoritmos que permiten la toma de decisiones con un esquema similar a un árbol, basados en evaluaciones dicotómicas (Sí/No). Las decisiones se basan en fórmulas para medir la impureza en las regiones analizadas. Dentro de estas fórmulas tenemos la de impureza de Gini, de entropía, de Bayes [78], [79].

En este estudio, para la clasificación de emociones basadas en EEG, se utilizaron SVMs del tipo RBF, y polinómico, debido a que, según los reviews más recientes, es el método

más popular de clasificación con el 53% [5], y a su vez, es el que ha sido elegido como el método con mejores resultados en el 59% de los estudios [2].

Mediante pruebas con las diferentes características se buscó determinar cuál de los tipos de SVM es el que mejor nivel de acierto obtiene. Sin embargo, de acuerdo a la teoría, se puede inferir que el SVM RBF obtendría mejores resultados [80]. En las primeras pruebas se procedió a evaluar la utilización de PCA como método para la reducción de la dimensionalidad, para lo cual se realizaron pruebas de los niveles de acierto de los algoritmos aplicándolos con y sin PCA. Luego de verificar que en las pruebas iniciales PCA daba siempre el mejor resultado, se procedió a utilizar PCA en forma predeterminada en todos los casos.

El método de validación cruzada consiste en dividir en partes iguales a los datos, utilizando una de las partes para la evaluación y las otras para el entrenamiento del modelo. El proceso debe repetirse tantas veces como partes en las cuales se han dividido los datos. La utilización de este método ayuda a asegurar la robustez del modelo [81].

En este estudio se utilizó el método de K-fold para la validación cruzada con un valor de  $K=4$ . K-fold consiste en dividir de manera aleatoria el set de entrenamiento en  $k$  bloques (sin reemplazo), de los cuales  $k-1$  bloques de datos son utilizados para entrenar el modelo, y el bloque restante se utiliza para la evaluación del modelo. Este proceso se debe repetir  $k$  veces, con lo cual se consigue obtener a su vez  $k$  modelos. Posteriormente se obtiene el promedio de desempeño de todos los modelos [59], [81].

Adicionalmente se procedió a la normalización de los datos, para la cual se utilizó el método Z-score. Este método consiste en la aplicación de la ecuación 4.14.

$$z = \frac{x - \mu}{\sigma} \quad (4.14)$$

En donde  $\mu$  representa la media y  $\sigma$  la desviación típica o estándar de los datos.

La normalización nos ayuda para la comparación de conjuntos de datos con características diferentes, tal es el caso de sets o tipos de datos dispares [81].

Como ya se ha explicado anteriormente, para reducir la dimensión de los datos y mejorar el rendimiento computacional se utilizó el método de Análisis de Componentes Principales (PCA). PCA es una técnica de transformación lineal no supervisada, utilizada ampliamente para la extracción de características, reducción de la dimensionalidad de datos, análisis de datos exploratorios, etc. El modo de operación de esta técnica es buscar la dirección de máxima varianza en datos con alta dimensionalidad y transformarlos adaptándolos a un subespacio con menor dimensión que el espacio inicial [59].

En todos los casos en que se usó PCA se buscó que el valor explicado sea al menos del 0.99, por lo cual, se fue variando la cantidad de componentes hasta conseguir ese objetivo, por ejemplo, en el caso de las pruebas realizadas con características individuales se fue incrementando el valor de componentes desde 10 hasta llegar a 60 en el que el valor explicado llegó a 0.99. En el caso de las pruebas individuales el valor es fijo pues se usaron todos los canales a la vez, no así en las pruebas con supervectores, en donde se realizaron búsquedas de canales óptimos, y se inició con un valor de componentes que garantice, como se había mencionado, el 0.99 de valor explicado, y se los fue incrementando a medida que se adicionaban canales para poder mantener dicho valor.

De este modo, en las pruebas realizadas con las características individuales se utilizó una cantidad de 60 componentes, variando en el caso de los supervectores con pocas características a 140 componentes y para los supervectores con más características a 240 componentes. En el caso de las pruebas de fuerza bruta se inició en los supervectores más básicos con 10 componentes, a los cuales se les aumentaba 5 componentes por cada canal que se iba agregando. En el caso del Supervector con más características, se inició con 30 componentes y se aumentaba 10 componentes por cada canal adicionado. Con esto se consiguió mantener en 0.99 el valor explicado en cada prueba. Los valores referentes a los componentes utilizados se especifican en los resultados de cada prueba realizada, en la sección 5.

Para buscar los parámetros óptimos se realizó una técnica denominada búsqueda en grid, la cual, es muy popular para esta labor. Esta técnica consiste en determinar el mejor ajuste mediante la mejor combinación de parámetros posible. De este modo, se prueba el desempeño de un determinado algoritmo de aprendizaje automático [81]. En el caso de

los SVM, su probó variando los valores de C y el grado para el caso del SVM polinómico, y C y gamma para el caso del SVM RBF.

Para la búsqueda en grid se utilizaron los siguientes valores iniciales en los parámetros:

#### **SVM Polinómico:**

Parámetro C:

[1e-10,1e-9,1e-8,1e-7,1e-6,1e-5,1e-4,1e-3,1e-2,1e-1,1e0,1e1,1e2,1e3,1e4,1e5,1e6,1e7,1e8,1e9,1e10]

Parámetro Grado:

[2,3,4]

#### **SVM RBF:**

Parámetro C:

[1e-10,1e-9,1e-8,1e-7,1e-6,1e-5,1e-4,1e-3,1e-2,1e-1,1e0,1e1,1e2,1e3,1e4,1e5,1e6,1e7,1e8,1e9,1e10]

Parámetro Gamma:

[0.0001,0.001,0.01,0.1,1,10,100,100,1000]

Luego de realizada la búsqueda inicial se debe proceder a realizar búsquedas sucesivas en profundidad (zoom), en el rango de valores adyacentes a los valores con mayor nivel de acierto (zonas rojas o naranjas). Luego de llegar a un punto en el que los valores de acierto más alto se estabilicen, se procede a finalizar la búsqueda y se toman los valores de los parámetros correspondientes como los óptimos.

## **4.5. Método De Fuerza Bruta**

Este método consiste en ir probando individualmente el nivel de acierto de cada canal y las posibles combinaciones entre ellos, agrupándolos progresivamente hasta encontrar aquella combinación que obtenga un mejor nivel de acierto (canales óptimos). Se inicia buscando el canal con mejor nivel de acierto a nivel individual en la primera iteración. En la segunda iteración se agrupará en pares a ese canal con los demás canales restantes y se encontrará cuál de esos pares tuvo mayor acierto. Este proceso se repetirá incrementando progresivamente un canal adicional al grupo de canales con mejor acierto

de la iteración anterior, hasta llegar a probar el grupo con la totalidad de canales. Finalmente se identificará la iteración en la que se obtuvo el mejor nivel de acierto de todas las pruebas y las posiciones de canales óptimos asociados a esa iteración. Se exponen adicionalmente de cada prueba el número de iteraciones realizadas, el valor inicial de acierto y el máximo valor de acierto alcanzado.

Para realizar este método es preciso haber realizado previamente la búsqueda en grid, con el objetivo de dar con los parámetros óptimos. Estos parámetros se deben ingresar en el algoritmo de búsqueda de canales óptimos previo al inicio del proceso de búsqueda. Finalmente se procedió a elaborar una tabla comparativa (al final de la sección 5.1.2.2.) con los valores de acierto de los supervectores para facilitar la comparación y búsqueda de los resultados con mayores niveles de acierto y seleccionar así el Supervector con las configuraciones y canales óptimos.

Como aporte adicional a este estudio, se crearon 2 supervectores con los datos del set DEAP [8]. Para el primero se procedió a utilizar la combinación de características del Supervector óptimo obtenido con los datos del set SEED [9], y luego para el segundo, se utilizó la combinación de características del primero más la característica Valencia. Se tomó en consideración a la Valencia pese a tener niveles de acierto relativamente bajos, porque en el caso del set DEAP [8], solo se clasificó 2 tipos de emociones: positivas y negativas, es decir, con alta o baja valencia. Esto se detalla en la sección 5.2.



## **5. RESULTADOS**

En este capítulo se muestran los resultados obtenidos de las pruebas realizadas con ambos sets de datos, mediante la extracción de las características individuales y su posterior combinación en supervectores descritas en el capítulo 4.

Inicialmente se muestran los resultados de las pruebas realizadas mediante la aplicación de los SVM polinomial y RBF en las características que vienen pre calculadas por los autores del set de datos SEED [9], (DE y PSD con Media Móvil) sin utilizar validación cruzada, para luego exponer los resultados de las pruebas con valores de características calculadas de las señales de los sets de datos, utilizando la validación cruzada.

Los resultados obtenidos en las búsquedas en grid, se pueden evidenciar en los gráficos de color correspondientes a cada prueba (ubicados en Apéndice A), en los cuales, por el color se puede apreciar la combinación óptima de parámetros, siendo representados los valores más altos de acierto por los tonos rojos más oscuros, mientras que los valores más bajos por los tonos azules más oscuros. En la mayoría de los casos se muestran 2 imágenes: la primera corresponde a la búsqueda inicial y la segunda a la búsqueda en la que se encontraron los valores de parámetros óptimos. Esto se aplica, tanto en las pruebas con características individuales como en las realizadas con supervectores de características.

Junto a las imágenes de las pruebas se detallan en una tabla resumen los valores obtenidos en las búsquedas para facilitar la comparación de resultados. En estas, se procedió a marcar con resaltador amarillo el resultado con mejor nivel de acierto y se registró los valores de los parámetros con los que se logró ese nivel.

### **5.1. Pruebas Realizadas con Datos del Set SEED [9].**

#### **5.1.1. Características Extraídas (pre calculadas) del Set de Datos**

En esta sección se exponen los resultados de las pruebas realizadas sobre las características DE y PSD con Media Móvil pre calculadas del set de datos (descritas en las secciones 4.2.1.1. y 4.2.2.1.), con SVM polinomial y RBF. Se hicieron pruebas de los

algoritmos sin y con PCA para reducir la dimensionalidad de los datos y a su vez sin la utilización de la validación cruzada. Primero se muestran los resultados de las pruebas individuales con cada característica y luego los resultados de la combinación de estas en un Supervector.

**5.1.1.1. Entropía Diferencial:** Los resultados se muestran en la tabla 5. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 28, con SVM Polinomial sin PCA en la figura 29, con SVM RBF con PCA en la figura 30, y con SVM RBF sin PCA en la figura 31.

Característica:		Entropía Diferencial (DE)	
Tipo SVM	PCA	Acierto	Parámetros
Polinomial	Sí	0.7964	
Polinomial	No	0.8053	
RBF	Sí	0.8495	C=90 Gamma=0.0015
RBF	No	0.7876	

Tabla 5 Resumen de las pruebas con Entropía Diferencial.

**5.1.1.2. PSD con Media Móvil:** Los resultados se muestran en la tabla 6. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 32, con SVM Polinomial sin PCA en la figura 33, con SVM RBF con PCA en la figura 34, y con SVM RBF sin PCA en la figura 35.

Característica:		PSD Media Móvil	
Tipo SVM	PCA	Acierto	Parámetros
Polinomial	Sí	0.6991	C=100 Grado=3
Polinomial	No	0.5663	
RBF	Sí	0.6814	
RBF	No	0.3097	

Tabla 6 Resumen de las pruebas con PSD con Media Móvil.

Como se puede apreciar en las tablas resumen, el valor más alto de acierto corresponde a la característica Entropía Diferencial, utilizando SVM RBF y PCA. Es importante destacar que la diferencia de acierto óptimo entre ambas características corresponde a 0.15.



### 5.1.1.3. Supervector 0

En esta sección se exponen los resultados de las pruebas realizadas con el supervector inicial, llamado Supervector 0, en el cual se combinan las características probadas individualmente: Entropía Diferencial y PSD con Media Móvil.

#### Características: Entropía Diferencial (DE) y PSD con Media Móvil

Los resultados se muestran en la tabla 7. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 36 y con SVM RBF con PCA en la figura 37.

Característica:		Supervector 0	
Tipo SVM	PCA	Acierto	Parámetros
Polinomial	Sí	0.8053	
RBF	Sí	0.8141	C=200 Gamma=0.001

Tabla 7 Resumen de las pruebas con el Supervector 0.

Al analizar los resultados obtenidos se puede apreciar que el valor de acierto óptimo del Supervector 0, no consiguió superar el valor obtenido con la característica individual Entropía Diferencial. Esto puede deberse a que la característica de Entropía Diferencial obtuvo mejores resultados con la aplicación del SVM RBF, mientras que la característica PSD con media móvil obtuvo mejores resultados con el SVM polinómico, así como también a la diferencia de nivel de acierto de 0,15 obtenida en las pruebas individuales.

## 5.1.2. Características Calculadas a partir de las Señales del Set de Datos

En las siguientes pruebas se utilizó en todos los casos la validación cruzada, de acuerdo con lo especificado en la sección 4.4. Para todas las pruebas se utilizaron todos los canales.

### 5.1.2.1. Pruebas Individuales

A continuación, se exponen los resultados de las pruebas realizadas con características individuales con el objetivo de elegir aquellas con niveles de acierto más elevados y proceder a combinarlas para la creación de supervectores.

**Media:** Los resultados se muestran en la tabla 8. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 38, con SVM Polinomial sin PCA en la figura 39, con SVM RBF con PCA en la figura 40, y con SVM RBF sin PCA en la figura 41.

Característica:		Media	
Tipo SVM	PCA	Acierto	Parámetros
Polinomial	Sí	0.3978	
Polinomial	No	0.3311	
RBF	Sí	0.4178	C=25 Gamma=0.05
RBF	No	0.3802	

Tabla 8 Resumen de las pruebas con Media.

En las pruebas realizadas previamente, se procedió a probar el nivel de acierto obtenido con y sin la utilización de PCA, mostrando los resultados en todos los casos un mejor nivel de acierto al utilizar PCA, además se evidenció un menor tiempo de procesamiento al utilizar PCA, corroborando lo explicado por Duan et al [48], al recomendar el uso de PCA para reducir la dimensionalidad y aumentar así el rendimiento y estabilidad computacional. Por ello, en las pruebas posteriores se procedió a utilizar en todos los casos PCA.

**Valor Máximo:** Los resultados se muestran en la tabla 9. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 42, y con SVM RBF con PCA en la figura 43.

Característica:		Valor Máximo	
Tipo SVM		Acierto	Parámetros
Polinomial		0.4732	
RBF		0.4888	C=900 Gamma=0.001

Tabla 9 Resumen de las pruebas con Valor Máximo.

**Valor Mínimo:** Los resultados se muestran en la tabla 10. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 44, y con SVM RBF con PCA en la figura 45.

Característica: Mínimo		
Tipo SVM	Acierto	Parámetros
Polinomial	0.4533	
RBF	0.5065	C=60 Gamma=0.001

Tabla 10 Resumen de las pruebas con Valor Mínimo

**Desviación Típica:** Los resultados se muestran en la tabla 11. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 46, y con SVM RBF con PCA en la figura 47.

Característica: Desviación Típica		
Tipo SVM	Acierto	Parámetros
Polinomial	0.5732	
RBF	0.5976	C=200 Gamma=0.001

Tabla 11 Resumen de las pruebas con Desviación Típica.

**Sesgo o Asimetría:** Los resultados se muestran en la tabla 12. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 48, y con SVM RBF con PCA en la figura 49.

Característica: Sesgo		
Tipo SVM	Acierto	Parámetros
Polinomial	0.3734	
RBF	0.3934	C=5000 Gamma=0.005

Tabla 12 Resumen de las pruebas con Sesgo o Asimetría.

**Curtosis:** Los resultados se muestran en la tabla 13. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 50, y con SVM RBF con PCA en la figura 51.

Característica: Curtosis		
Tipo SVM	Acierto	Parámetros
Polinomial	0.3667	
RBF	0.3823	C=60000 Gamma=0.0001

Tabla 13 Resumen de las pruebas con Curtosis.

**HJORTH Movilidad:** Los resultados se muestran en la tabla 14. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 52, y con SVM RBF con PCA en la figura 53.

Característica: HJORTH MOVILIDAD		
Tipo SVM	Acierto	Parámetros
Polinomial	0.5468	
RBF	0.7180	C=33 Gamma=0.003

Tabla 14 Resumen de las pruebas con HJORTH Movilidad.

**HJORTH Complejidad:** Los resultados se muestran en la tabla 15. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 54, y con SVM RBF con PCA en la figura 55.

Característica: HJORTH COMPLEJIDAD		
Tipo SVM	Acierto	Parámetros
Polinomial	0.5266	
RBF	0.7845	C=40 Gamma=0.008

Tabla 15 Resumen de las pruebas con HJORTH Complejidad.

**Detrended Fluctuation Analysis (DFA):** Los resultados se muestran en la tabla 16. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 56, y con SVM RBF con PCA en la figura 57.

Característica:	DETRENDED FLUCTUATION ANALYSIS (DFA)	
Tipo SVM	Acierto	Parámetros
Polinomial	0.6888	
RBF	0.7509	C=2.8 Gamma=0.009

Tabla 16 Resumen de las pruebas con DFA.

**Cruces por Cero:** Los resultados se muestran en la tabla 17. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 58, y con SVM RBF con PCA en la figura 59.

Característica:	CRUCES POR CERO	
Tipo SVM	Acierto	Parámetros
Polinomial	0.6444	
RBF	0.8156	C=1.6 Gamma=0.0021

Tabla 17 Resumen de las pruebas con Cruces por Cero

**PSD Simple (Media):** Los resultados se muestran en la tabla 18. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 60, y con SVM RBF con PCA en la figura 61.

Característica:	PSD SIMPLE (MEDIA)	
Tipo SVM	Acierto	Parámetros
Polinomial	0.5310	
RBF	0.5821	C=75 Gamma=0.001

Tabla 18 Resumen de las pruebas con PSD Simple (Media).

**PSD Media Móvil (Media):** Los resultados se muestran en la tabla 19. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 62, y con SVM RBF con PCA en la figura 63.

Característica:	PSD MEDIA MÓVIL (MEDIA)	
Tipo SVM	Acierto	Parámetros
Polinomial	0.5466	
RBF	0.5753	C=108 Gamma=0.001

Tabla 19 Resumen de las pruebas con PSD Media Móvil (Media).

**Wavelet db1 (Desviación Estándar):** Los resultados se muestran en la tabla 20. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 64, y con SVM RBF con PCA en la figura 65.

Característica:	WAVELET DB1 (Desviación Estándar)	
Tipo SVM	Acierto	Parámetros
Polinomial	0.5778	
RBF	0.6155	C=18 Gamma=0.001

Tabla 20 Resumen de las pruebas con Wavelet DB1 (Desviación Estándar).

**Higuchi Fractal Dimension (HFD):** Los resultados se muestran en la tabla 21. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 66, y con SVM RBF con PCA en la figura 67.

Característica:	HIGUCHI FRACTAL DIMENSION (HFD)	
Tipo SVM	Acierto	Parámetros
Polinomial	0.5667	
RBF	0.6734	C=2.2 Gamma=0.007

Tabla 21 Resumen de las pruebas con Higuchi Fractal Dimension (HFD).

**Petrosian Fractal Dimension (PFD):** Los resultados se muestran en la tabla 22. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 68, y con SVM RBF con PCA en la figura 69.

Característica:	PETROSIAN FRACTAL DIMENSION (PFD)	
Tipo SVM	Acierto	Parámetros
Polinomial	0.5734	
RBF	0.6866	C=20.2 Gamma=0.0017

Tabla 22 Resumen de las pruebas con Petrosian Fractal Dimension (PFD)

**Valencia:** Los resultados se muestran en la tabla 23. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 70, y con SVM RBF con PCA en la figura 71.

Característica:	VALENCIA	
Tipo SVM	Acierto	Parámetros
Polinomial	0.3512	
RBF	0.4045	C=0.3 Gamma=8

Tabla 23 Resumen de las pruebas con Valencia

En la tabla 24 se detalla un resumen con los valores de acierto óptimos de cada una de las pruebas individuales. En base a los resultados obtenidos, se procedió a utilizar las características con valores más altos de acierto a nivel individual para la creación de supervectores.

Característica	SVM	Acierto máximo
Cruces por Cero	RBF	0.8156
HJORTH Complejidad	RBF	0.7845
DFA	RBF	0.7509
HJORTH Movilidad	RBF	0.7180
PFD	RBF	0.6866
HFD	RBF	0.6734
Wavelet db1 (Desv. Tip.)	RBF	0.6155
Desviación Típica	RBF	0.5976
PSD Simple (Media)	RBF	0.5821
PSD Media Móvil (Media)	RBF	0.5753
Valor Mínimo	RBF	0.5065
Valor Máximo	RBF	0.4888
Media	RBF	0.4178
Valencia	RBF	0.4045
Sesgo o Asimetría	RBF	0.3934
Curtosis	RBF	0.3823

*Tabla 24 Resumen aciertos óptimos características individuales*

### 5.1.2.2. Pruebas con Supervectores

En las siguientes pruebas se procedieron a combinar las características con valores de acierto más altos para así determinar el supervector óptimo, es decir aquel que tenga un nivel de acierto mayor. Luego de los resultados de las pruebas con las búsquedas en grid, se presentan resultados de las pruebas mediante fuerza bruta para buscar la combinación de canales óptimos, mediante las cuales se logra en todos los casos mejorar el nivel de acierto de los supervectores. Se detallan para cada prueba las características que componen el Supervector y el número de componentes utilizados para la aplicación de PCA. En el caso de la aplicación del método de fuerza bruta por ser variable el número de canales, también se varía el número de componentes en la aplicación de PCA en cada iteración, por lo cual se indica el número de componentes iniciales y el aumento que se realiza en cada iteración para garantizar un valor explicado de al menos 0.99, por ejemplo: Componentes = 10 + Iteraciones\*5. Adicionalmente se muestra una gráfica con los niveles de acierto de cada iteración, así como el detalle de las posiciones óptimas de canales, el acierto máximo y la iteración en la que se consiguió obtener ese nivel de acierto.



## Supervector 1

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA**  
**PCA (140 componentes)**

Los resultados se muestran en la tabla 25. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 72, y con SVM RBF con PCA en la figura 73.

Característica:	SUPERVECTOR 1	
Tipo SVM	Acierto	Parámetros
Polinomial	0.7311	
RBF	0.8533	C=10.5 Gamma=0.0008

Tabla 25 Resumen de las pruebas con Supervector 1

## Aplicación del Método de Fuerza Bruta

**Componentes = 10 + Iteraciones\*5**

Posiciones: [31, 0, 51, 23, 58, 34, 42, 41, 21, 1, 57, 14, 39, 13, 54, 56, 35, 61, 25, 20, 30]

Acierto Máximo: 0.8734

Iteración del Acierto Máximo: 21

En la figura 19 se muestran los resultados obtenidos con el método de fuerza bruta.




Figura 19 Método de Fuerza Bruta con Supervector 1.

## Supervector 2

**Características:** HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, Desviación Típica

**PCA (140 componentes)**

Los resultados se muestran en la tabla 26. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 74, y con SVM RBF con PCA en la figura 75.

Característica:	SUPERVECTOR 2	
Tipo SVM	Acierto	Parámetros
Polinomial	0.6978	
RBF	0.8445	C=11.7 Gamma=0.0015

Tabla 26 Resumen de las pruebas con Supervector 2

## Aplicación del Método de Fuerza Bruta

**Componentes = 10 + Iteraciones\*5**

Posiciones: [23, 0, 58, 21, 46, 57, 38, 51, 31, 14, 30, 55, 25, 53, 24, 43, 50, 10, 56, 8, 61, 6, 13, 54, 37, 35, 1, 17, 41, 59, 2, 47, 39, 4, 44]

Acierto Máximo: 0.8844

Iteración del Acierto Máximo: 35

En la figura 20 se muestran los resultados obtenidos con el método de fuerza bruta.




Figura 20 Método de Fuerza Bruta con Supervector 2.

### Supervector 3

**Características: HJORTH Complejidad, HJORTH Movilidad, DFA**

**PCA (140 componentes)**

Los resultados se muestran en la tabla 27. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 76, y con SVM RBF con PCA en la figura 77.

Característica:	SUPERVECTOR 3	
Tipo SVM	Acierto	Parámetros
Polinomial	0.7067	
RBF	0.8089	C=12.45 Gamma=0.001

Tabla 27 Resumen de las pruebas con Supervector 3

### Aplicación del Método de Fuerza Bruta

**Componentes = 10 + Iteraciones\*5**

Posiciones: [31, 0, 23, 28, 36, 16, 10, 19, 7, 5, 50, 14, 27, 3, 20, 46, 17, 13, 6, 25, 22, 21, 11, 12, 18, 54, 24, 1, 45]

Acierto Máximo: 0.8468

Iteración del Acierto Máximo: 29

En la figura 21 se muestran los resultados obtenidos con el método de fuerza bruta.




Figura 21 Método de Fuerza Bruta con Supervector 3.

## Supervector 4

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD  
PCA (140 componentes)**

Los resultados se muestran en la tabla 28. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 78, y con SVM RBF con PCA en la figura 79.

Característica:	SUPERVECTOR 4	
Tipo SVM	Acierto	Parámetros
Polinomial	0.7067	
RBF	0.8333	C=30250 Gamma=0.0021

Tabla 28 Resumen de las pruebas con Supervector 4

## Aplicación del Método de Fuerza Bruta

**Componentes = 10 + Iteraciones\*5**

Posiciones: [31, 35, 23, 14, 42, 21, 55, 59, 46, 12, 24, 13, 17, 50, 48, 30, 51, 53, 20, 45, 29, 2, 33, 38]

Acierto Máximo: 0.8756

Iteración del Acierto Máximo: 24

En la figura 22 se muestran los resultados obtenidos con el método de fuerza bruta.




Figura 22 Método de Fuerza Bruta con Supervector 4.

## Supervector 5

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Cruces por Ceros**  
**PCA (140 componentes)**

Los resultados se muestran en la tabla 29. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 80, y con SVM RBF con PCA en la figura 81.

Característica:	SUPERVECTOR 5	
Tipo SVM	Acierto	Parámetros
Polinomial	0.7509	
RBF	0.8666	C=5.5 Gamma=0.0011

Tabla 29 Resumen de las pruebas con Supervector 5

## Aplicación del Método de Fuerza Bruta

**Componentes = 30 + Iteraciones\*10**

Posiciones: [31, 0, 14, 56, 8, 2, 3, 61, 21, 60, 36, 23, 12, 41, 29, 9, 43, 24, 55, 33, 40, 1, 50, 13, 34, 6, 7, 49]

Acierto Máximo: 0.9067

Iteración del Acierto Máximo: 27

En la figura 23 se muestran los resultados obtenidos con el método de fuerza bruta.




Figura 23 Método de Fuerza Bruta con Supervector 5.

## Supervector 6

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Cruces por Cero**

**PCA (140 componentes)**

Los resultados se muestran en la tabla 30. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 82, y con SVM RBF con PCA en la figura 83.

Característica:	SUPERVECTOR 6	
Tipo SVM	Acierto	Parámetros
Polinomial	0.7688	
RBF	0.8689	C=4.4 Gamma=0.0007

Tabla 30 Resumen de las pruebas con Supervector 6

## Aplicación del Método de Fuerza Bruta

**Componentes = 30 + Iteraciones\*9**

Posiciones: [23, 0, 49, 43, 3, 22, 14, 9, 26, 59, 34, 38, 2, 32, 21, 57, 42, 33, 60, 50, 48, 8, 40, 51]

Acierto Máximo: 0.8911

Iteración del Acierto Máximo: 23

En la figura 24 se muestran los resultados obtenidos con el método de fuerza bruta.




Figura 24 Método de Fuerza Bruta con Supervector 6.

## Supervector 7

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Wavelet db1, Cruces por Ceros**  
**PCA (240 componentes)**

Los resultados se muestran en la tabla 31. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 84, y con SVM RBF con PCA en la figura 85.

Característica:	SUPERVECTOR 7	
Tipo SVM	Acierto	Parámetros
Polinomial	0.7244	
RBF	0.8688	C=13 Gamma=0.0006

Tabla 31 Resumen de las pruebas con Supervector 7

## Aplicación del Método de Fuerza Bruta

**Componentes = 30 + Iteraciones\*10**

Posiciones: [23, 0, 54, 30, 17, 9, 31, 43, 8, 36, 13, 59, 41, 50, 33, 2, 22, 25, 44, 34, 1, 48, 49, 21, 20, 3]

Acierto Máximo: 0.9022

Iteración del Acierto Máximo: 25

En la figura 25 se muestran los resultados obtenidos con el método de fuerza bruta.




Figura 25 Método de Fuerza Bruta con Supervector 7.

## Supervector 8

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Cruces por Ceros, Valencia**  
**PCA (240 componentes)**

Los resultados se muestran en la tabla 32. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM Polinomial con PCA en la figura 86, y con SVM RBF con PCA en la figura 87.

Característica:	SUPERVECTOR 8	
Tipo SVM	Acierto	Parámetros
Polinomial	0.7465	
RBF	0.8645	C=9 Gamma=0.0009

*Tabla 32 Resumen de las pruebas con Supervector 8*

## Canales Óptimos

Dado que, para el cálculo de la Valencia se requiere de más de un canal, y de forma más exacta, se requieren 2 únicos canales (F3 y F4), el valor resultante de la misma se asigna a cada ensayo o evento, no a cada canal, como todas las características utilizadas anteriormente, por lo cual, se debe utilizar otro tipo de cómputo para obtener el nivel de acierto correspondiente. Por ello, se procedió a utilizar los mismos canales óptimos del supervector con mayor acierto (HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Cruces por Cero). A estos datos se les añadió los valores de Valencia, procediendo a calcular el nivel de acierto del conjunto, realizando previamente una búsqueda en grid.

Los canales óptimos y sus respectivas posiciones son:

Posiciones: [31, 0, 14, 56, 8, 2, 3, 61, 21, 60, 36, 23, 12, 41, 29, 9, 43, 24, 55, 33, 40, 1, 50, 13, 34, 6, 7, 49]

Iteración del Acierto Máximo: 27

Con ello se logró obtener los siguientes resultados:

Acierto Máximo: 0.9045

Parámetros: C=5.5 y Gamma=0.00077



A continuación, se presenta en la tabla 33 un resumen de los valores de acierto máximo obtenidos por cada Supervector, tanto en las pruebas con todos los canales, como en las pruebas con el método de fuerza bruta para la obtención de canales óptimos.

Supervector	Acierto Máximo con Todos los Canales	Acierto Máximo con Canales Óptimos (Fuerza Bruta)
1	0.8533	0.8734
2	0.8445	0.8844
3	0.8089	0.8468
4	0.8333	0.8756
5	0.8666	0.9067
6	0.8689	0.8911
7	0.8688	0.9022
8	0.8645	0.9045

*Tabla 33 Resumen de valores de acierto máximo tanto al utilizar todos los canales, como al utilizar únicamente los canales óptimos (método de Fuerza Bruta).*

En la tabla 33 podemos observar que los supervectores con mayor nivel de acierto son el Supervector 5 y el Supervector 8, con niveles de acierto máximos de 0.9067 y 0.9045 respectivamente, en ambos casos con la aplicación del método de Fuerza Bruta. Es importante destacar que en todos los casos se consiguieron niveles más altos de acierto mediante la aplicación del método de fuerza bruta. Es importante destacar que estos valores superan los obtenidos en el artículo original del set de datos SEED [9], en el cual se consigue un nivel de acierto máximo de 86.08 utilizando todos los canales y de 86.65 utilizando 12 canales (FT7, FT8, T7, T8, C5, C6, TP7, TP8, CP5, CP6, P7 y P8).

## 5.2. Pruebas Realizadas con Datos del Set DEAP [8].

Como un aporte adicional a este TFM se procedió a realizar un par de pruebas con el set de datos DEAP, utilizando como base la combinación de características de los Supervectores que alcanzaron mayores niveles de acierto en las pruebas con el set de datos SEED. Sin embargo, fue necesario aumentar el número de componentes en la aplicación de PCA para garantizar un valor explicado de al menos 0.99.

### Supervector DEAP 1

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Cruces por Ceros.**

**PCA (650 componentes)**

Los resultados se muestran en la tabla 34. En el apéndice A, se muestran las gráficas de las búsquedas en grid con SVM RBF con PCA en la figura 88.

Característica:	SUPERVECTOR DEAP 1	
Tipo SVM	Acierto	Parámetros
RBF	0.5789	C=5.5 Gamma=0.00008

*Tabla 34 Resumen de las pruebas con Supervector DEAP 1*

### Aplicación del Método de Fuerza Bruta

**Componentes = 32 + Iteraciones\*25**

Posiciones: [0, 19, 7, 25, 28, 4, 11, 8, 31, 15, 20, 14, 26, 3, 1, 10, 2, 17, 18, 29, 13, 6, 9, 16, 5, 23, 22, 27, 30, 24, 12, 21]

Acuerdo Máximo: **0.5938**

Iteración del Acuerdo Máximo: 23

En la figura 26 se muestran los resultados obtenidos con el método de fuerza bruta.




Figura 26 Método de Fuerza Bruta con Supervector DEAP 1

## Supervector DEAP 2

**HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Cruces por Ceros, Valencia.**

**PCA (650 componentes)**




Figura 27 Supervector DEAP 2: Búsqueda en grid SVM RBF con PCA (Canales óptimos)

## Canales Óptimos

De igual manera que en el análisis realizado en el set de datos SEED [9], para el cálculo de la Valencia se requiere de más de un canal, y de forma más exacta, se requieren 2 únicos canales (F3 y F4), el valor resultante de la misma se asigna a cada ensayo o evento, no a cada canal, por lo cual se procedió a utilizar los mismos canales óptimos del supervector con mayor acierto (HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Cruces por Cero). A estos datos se les añadió los valores de Valencia, procediendo a calcular el nivel de acierto del conjunto, realizando previamente una búsqueda en grid, cuyos resultados se muestran en la figura 27.

Los canales óptimos y sus respectivas posiciones son:

Posiciones: [31, 0, 14, 56, 8, 2, 3, 61, 21, 60, 36, 23, 12, 41, 29, 9, 43, 24, 55, 33, 40, 1, 50, 13, 34, 6, 7, 49]

Iteración del Acierto Máximo: 27

Con ello se logró obtener los siguientes resultados:

Acierto Máximo: 0.5969 con parámetros:  $C=7$  y  $\text{Gamma}=0.00006$

El vector óptimo en este caso resultó ser el segundo, con un nivel de acierto de 0.5969.

Es importante destacar que el nivel de acierto más alto obtenido en las pruebas con el set de datos DEAP [8], es mucho menor que los obtenidos tanto con el set de datos SEED [9], como en el artículo original del set de datos SEED [9], con valores de nivel de acierto máximo de 0.9067 y de 86.65 respectivamente.

## **6. CONCLUSIONES Y TRABAJO FUTURO**

### **6.1. Conclusiones**

El presente TFM ha logrado cumplir con los objetivos planteados originalmente, los cuales fueron:

Objetivo General:

Estudiar los principales métodos y la combinación de técnicas para la extracción de características y clasificación de emociones basadas en señales EEG, que puedan mediante su combinación mejorar el rendimiento.

Objetivos Específicos:

1. Elaborar el estado del arte referente a la Computación Afectiva y a los métodos de extracción de características y clasificación de emociones basadas en EEG.
2. Buscar y estudiar sets de datos adecuados para la aplicación de los métodos de extracción de características y clasificación de emociones basadas en EEG.
3. Estudiar y aplicar sobre los sets de datos los métodos para la extracción de características y clasificación de emociones basadas en EEG.
4. Buscar posibles combinaciones de diversas técnicas y métricas para aumentar el nivel de acierto en el contexto del reconocimiento de emociones basadas en EEG.

Por cuanto, se elaboró el estado del arte de la Computación Afectiva, iniciando con una revisión de los aspectos más relevantes de las BCIs como tipos, fases, así como de los diversos métodos para registrar la actividad cerebral y el procesamiento masivo de señales EEG, se continuó con el estudio de las fases principales de la Computación Afectiva, los modelos emocionales más relevantes, las emociones e importancia de estas, poniendo énfasis en el modelo Circumplejo de Russell que es el que nos permite tener una mejor comprensión del mundo de las emociones. Se analizaron además las aBCI y las aplicaciones más importantes de la Computación Afectiva, con lo cual se cumplió con el objetivo específico 1.

Se buscaron y analizaron sets de datos adecuados para la aplicación de métodos para la extracción de características y clasificación de emociones basadas en EEG, llegándose a utilizar en este estudio los sets SEED y DEAP, con lo cual se cumplió con el objetivo específico 2.

Se estudiaron y aplicaron diversos métodos para la extracción de características, como: el uso de Métricas estadísticas simples, parámetros HJORTH, Análisis de Fluctuación Descendente, Dimensión Fractal de Higuchi, Dimensión Fractal de Petrosian, Cruces por Ceros, Densidad Espectral de Potencia, Wavelets y las medidas de la emoción Valencia y Aerosal. En cuanto a los métodos de clasificación, se realizó una revisión de qué métodos han obtenido mejores resultados en investigaciones previas, por lo cual se analizaron en detalle y se aplicaron en las pruebas los SVM RBF y Polinómico, con lo cual se cumplió con el objetivos específico 3.

Adicionalmente se buscaron las posibles combinaciones de técnicas y métricas a través de la creación de supervectores, logrando mejorar los niveles de acierto. Llegando a alcanzar un 0.9, superando a los niveles de acierto de las características individuales. Se logró determinar el Supervector con la combinación óptima de características y de canales, mediante la búsqueda en grid y el uso del método de fuerza bruta, con lo cual se consiguió cumplir el objetivo específico 4.

Adicionalmente, se pudieron destacar las siguientes conclusiones dentro del estudio:

- Cruce por ceros resultó ser la característica individual con mayor nivel de acierto, por lo tanto, la más relevante. Eso se notó al crear los Supervectores, pues al combinar esta característica con las demás el nivel de acierto pudo superar el límite de 0.9 de nivel de acierto.
- Dentro de las métricas estadísticas simples, la desviación típica o estándar, es la que mejor nivel de acierto individual obtuvo, de hecho, el nivel de acierto obtenido fue amplio con respecto a las demás métricas. Esto motivó a que, al extraer características con la Wavelet, se utilice la desviación típica en lugar de la media para sintetizar en valores escalares los vectores de coeficientes. Por esto, se recomienda utilizar en casos como el de este estudio la Desviación Típica, en lugar de las otras métricas estadísticas simples, para obtener mejores resultados en el nivel de acierto.
- En la gran mayoría de los casos el nivel de acierto de un SVM RBF superó a del SVM Polinómico, por lo cual se puede concluir que de los 2, resulta más eficiente el SVM RBF en experimentos relacionados con el reconocimiento de emociones basados en EEG.

- La utilización de PCA fue fundamental pues, permitió incrementar el nivel de acierto y a su vez reducir el costo computacional.
- El uso de Wavelets no fue relevante, pues al ser calculado con la desviación típica, fue redundante con la información de la característica de métrica simple de desviación típica. Esto se lo puede notar porque el nivel de acierto de las Wavelets, tanto como el de la Desviación Típica resultaron similares.
- Con las características estudiadas ha sido suficiente para obtener buenos resultados en el set de datos SEED, no así en el set de datos DEAP. No se puede inferir nada en firme respecto a la razón de esta diferencia, pues para el efecto hace falta un estudio más profundo del set de datos DEAP, el cual, debería ser abordado con características adicionales a las utilizadas en este estudio. Lo que sí resulta evidente, son las diferentes particularidades que tiene cada set de datos, y en especial el set DEAP, de acuerdo con lo especificado en el segundo párrafo de la sección 4.
- El supervector óptimo fue el número 5, constituido por las características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica y Cruces por Ceros.
- Al incrementar las características de los supervectores, estos mejoraban el nivel de acierto, excepto cuando existían características redundantes como el caso de la Desviación típica o estándar y las Wavelets, como se explicó anteriormente.

## 6.2. Trabajo Futuro

- Investigar nuevas características para la construcción de nuevos supervectores enfocados a las particularidades del set de datos DEAP y realizar un estudio más profundo del mismo.
- Adaptar los procedimientos desarrollados para trabajar sobre los datos de otros sets como el HCI.
- Realizar una estandarización para la implementación de sets de datos de señales emociones, de acuerdo a lo comentado en [9], pues al momento, los resultados obtenidos con los sets de datos existentes no son factibles de comparar entre sí por las diferentes características que poseen.

- Investigar métricas y características adicionales para probarlas en los datos utilizados en este trabajo, y, adicionarlas a los supervectores aquí descritos para comprobar si se puede mejorar los niveles de acierto alcanzados.
- Realizar un estudio para verificar si es factible la utilización online de los métodos aplicados en el presente TFM.



# GLOSARIO

- **UAM:** Universidad Autónoma de Madrid
- **BCI:** Brain Computer Interface (Interfaz Cerebro Computador).
- **aBCI:** Interfaz Cerebro Computador Afectiva.
- **EEG:** Electroencefalografía
- **PCA:** Análisis de Componentes Principales.
- **SVM:** Máquinas de Vectores de Soporte
- **PSD:** Densidad Espectral de Potencia.



# BIBLIOGRAFÍA:

- [1] I. Daly, «Interfacing and Methods for Affective State Detection», *Brain-Computer Interfaces Handbook: Technological and Theoretical Advances. Chapter 8*, pp. 147–163, 2018.
- [2] S. M. Alarcao y M. J. Fonseca, «Emotions Recognition Using EEG Signals: A Survey», *IEEE Transactions on Affective Computing*, pp. 1-20, 2017.
- [3] B. García-Martínez, A. Martínez-Rodrigo, R. Zangróniz Cantabrana, J. Pastor García, y R. Alcaraz, «Application of Entropy-Based Metrics to Identify Emotional Distress from Electroencephalographic Recordings», *Entropy*, vol. 18, n.º 6, p. 221, jun. 2016.
- [4] A. Al-Nafjan, M. Hosny, A. Al-Wabil, y Y. Al-Ohali, «Classification of Human Emotions from Electroencephalogram (EEG) Signal using Deep Neural Network», *International Journal of Advanced Computer Science and Applications*, vol. 8, n.º 9, 2017.
- [5] A. Al-Nafjan, M. Hosny, Y. Al-Ohali, y A. Al-Wabil, «Review and Classification of Emotion Recognition Based on EEG Brain-Computer Interface System Research: A Systematic Review», *Applied Sciences*, vol. 7, n.º 12, p. 1239, dic. 2017.
- [6] M.-K. Kim, M. Kim, E. Oh, y S.-P. Kim, «A Review on the Computational Methods for Emotional State Estimation from the Human EEG», *Computational and Mathematical Methods in Medicine*, vol. 2013, pp. 1-13, 2013.
- [7] C. S. Nam, I. Choi, A. Wadeson, y M. Whang, «An Emerging Interaction Technology», p. 42.
- [8] S. Koelstra, J.-S. Lee, y T. Pun, «DEAP: A Database for Emotion Analysis using Physiological Signals», p. 15.
- [9] Wei-Long Zheng y Bao-Liang Lu, «Investigating Critical Frequency Bands and Channels for EEG-Based Emotion Recognition with Deep Neural Networks», *IEEE Transactions on Autonomous Mental Development*, vol. 7, n.º 3, pp. 162-175, sep. 2015.
- [10] F. Lotte, C. S. Nam, y A. Nijholt, «Introduction: Evolution of Brain-Computer Interfaces», *Brain-Computer Interfaces Handbook: Technological and Theoretical Advances. Chapter 1*, pp. 1-8, 2018.
- [11] M. A. Lebedev y M. A. L. Nicolelis, «Brain-machine interfaces: past, present and future», *Trends in Neurosciences*, vol. 29, n.º 9, pp. 536-546, sep. 2006.
- [12] M. Ahn, M. Lee, J. Choi, y S. Jun, «A Review of Brain-Computer Interface Games and an Opinion Survey from Researchers, Developers and Users», *Sensors*, vol. 14, n.º 8, pp. 14601-14633, ago. 2014.
- [13] D. S. Tan y A. Nijholt, Eds., *Brain-Computer Interfaces*. London: Springer London, 2010.
- [14] G. Pandarinathan, S. Mishra, A. Nedumaran, P. Padmanabhan, y B. Gulyás, «The Potential of Cognitive Neuroimaging: A Way Forward to the Mind-Machine Interface», *Journal of Imaging*, vol. 4, n.º 5, p. 70, may 2018.
- [15] «Report of the committee on methods of clinical examination in electroencephalography», *Electroencephalography and Clinical Neurophysiology*, vol. 10, n.º 2, pp. 370-375, may 1958.
- [16] Tomaton, *Electrode locations of International 10-20 system for EEG (electroencephalography) recording*. 2010.
- [17] Bruce Blaus, *Brain Mapping*. 2014.
- [18] D. Chen, L. Wang, G. Ouyang, y X. Li, «Massively Parallel Neural Signal Processing on a Many-Core Platform», *Computing in Science & Engineering*, vol. 13, n.º 6, pp. 42-51, nov. 2011.
- [19] A. I. Ianov, H. Kawamoto, y Y. Sankai, «Wearable parallel processing based high-resolution high-speed electroencephalogram monitoring integrated system», en *2012 IEEE/SICE International Symposium on System Integration (SII)*, Fukuoka, Japan, 2012, pp. 186-191.
- [20] L. Wang, D. Chen, R. Ranjan, S. U. Khan, J. Kolodziej, y J. Wang, «Parallel Processing of Massive EEG Data with MapReduce», en *2012 IEEE 18th International Conference on Parallel and Distributed Systems*, Singapore, Singapore, 2012, pp. 164-171.
- [21] *Bioinformatics and biomedical engineering*. New York, NY: Springer Berlin Heidelberg, 2016.

- [22] J. J. Escobar, J. Ortega, J. González, M. Damas, y A. F. Díaz, «Parallel high-dimensional multi-objective feature selection for EEG classification with dynamic workload balancing on CPU–GPU architectures», *Cluster Computing*, vol. 20, n.º 3, pp. 1881-1897, sep. 2017.
- [23] D. Chen, Y. Hu, C. Cai, K. Zeng, y X. Li, «Brain big data processing with massively parallel computing technology: challenges and opportunities: BRAIN BIG DATA PROCESSING», *Software: Practice and Experience*, vol. 47, n.º 3, pp. 405-420, mar. 2017.
- [24] Z. Juhasz, «Highly parallel online bioelectrical signal processing on GPU architecture», en *2017 40th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, Opatija, Croatia, 2017, pp. 340-346.
- [25] J. J. Escobar, J. Ortega, J. González, y M. Damas, «Improving Memory Accesses for Heterogeneous Parallel Multi-objective Feature Selection on EEG Classification», en *Euro-Par 2016: Parallel Processing Workshops*, vol. 10104, F. Desprez, P.-F. Dutot, C. Kaklamanis, L. Marchal, K. Molitorisz, L. Ricci, V. Scarano, M. A. Vega-Rodríguez, A. L. Varbanescu, S. Hunold, S. L. Scott, S. Lankes, y J. Weidendorfer, Eds. Cham: Springer International Publishing, 2017, pp. 372-383.
- [26] S. Poria, E. Cambria, R. Bajpai, y A. Hussain, «A review of affective computing: From unimodal analysis to multimodal fusion», *Information Fusion*, vol. 37, pp. 98-125, sep. 2017.
- [27] R. W. Picard, «Affective Computing», p. 16, 1995.
- [28] G. N. Yannakakis, «Enhancing health care via affective computing», *Malta Journal of Health Sciences*, n.º 5, p. 38, jun. 2018.
- [29] Lang, Peter, J., Margaret, M. Bradley, y Bruce N. Cuthbert, «International affective picture system (IAPS): Technical manual and affective ratings», *NIMH Center for the Study of Emotion and Attention*, pp. 39-58, 1997.
- [30] B. Kurdi, S. Lozano, y M. R. Banaji, «Introducing the Open Affective Standardized Image Set (OASIS)», *Behavior Research Methods*, vol. 49, n.º 2, pp. 457-470, abr. 2017.
- [31] Y. Dasdemir, E. Yildirim, y S. Yildirim, «Analysis of functional brain connections for positive–negative emotions using phase locking value», *Cognitive Neurodynamics*, vol. 11, n.º 6, pp. 487-500, dic. 2017.
- [32] J. Lichtenauer y M. Soleymani, «MAHNOB-HCI-TAGGING DATABASE», p. 19.
- [33] R. Kosti, J. M. Alvarez, A. Recasens, y A. Lapedriza, «Emotion Recognition in Context», en *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, 2017, pp. 1960-1968.
- [34] K. S. Young *et al.*, «Sensing emotion in voices: Negativity bias and gender differences in a validation study of the Oxford Vocal ('OxVoc') sounds database.», *Psychological Assessment*, vol. 29, n.º 8, pp. 967-977, ago. 2017.
- [35] Y. Ding, X. Hu, Z. Xia, Y.-J. Liu, y D. Zhang, «Inter-brain EEG Feature Extraction and Analysis for Continuous Implicit Emotion Tagging during Video Watching», *IEEE Transactions on Affective Computing*, p. 12, 2018.
- [36] Norman Denzin, *On Understanding Emotion*, 1.ª ed. Jossey-Bass, 1984.
- [37] K. R. Scherer, «Psychological models of emotion», *The neuropsychology of emotion*, vol. 137, n.º 3, pp. 137–162, 2000.
- [38] Bericat Alastuey, Eduardo, «Emociones», *Sociopedia. isa*, pp. 1-13, 2012.
- [39] «Gartner's 2016 Hype Cycle for Emerging Technologies Identifies Three Key Trends That Organizations Must Track to Gain Competitive Advantage». [En línea]. Disponible en: <https://www.gartner.com/newsroom/id/3412017>. [Accedido: 27-ago-2018].
- [40] Plutchik, Robert, «The nature of emotions.pdf», *American Scientist*, pp. 344-350, 2001.
- [41] «Robert Plutchik's Wheel of Emotions», *Wikipedia*. 17-ago-2018.
- [42] H. Lövhheim, «A new three-dimensional model for emotions and monoamine neurotransmitters», *Medical hypotheses*, vol. 78, n.º 2, pp. 341–348, 2012.
- [43] «Lövhheim cube of emotion», *Wikipedia*. 17-ago-2018.
- [44] José Miguel Mestre y Rocío Guil, *La regulación de las emociones: Una vía a la adaptación personal y social*. Madrid: Pirámide, 2012.

- [45] J. A. Russell, «A circumplex model of affect.», *Journal of Personality and Social Psychology*, vol. 39, n.º 6, pp. 1161-1178, 1980.
- [46] M. Murugappan, R. Nagarajan, y S. Yaacob, «Combining Spatial Filtering and Wavelet Transform for Classifying Human Emotions Using EEG Signals», *J. Med. Biol. Eng.*, vol. 31, n.º 1, p. 8, 2011.
- [47] Agustín Hernández, R. V. Ramirez, B. Alejandra, O. Zepahua, G. C. Robles, y I. L. Martínez, «Sistema de detección de emociones para la recomendación de recursos educativos», *Programación Matemática y Software*, p. 9, 2016.
- [48] R.-N. Duan, J.-Y. Zhu, y B.-L. Lu, «Differential entropy feature for EEG-based emotion classification», en *Neural Engineering (NER), 2013 6th International IEEE/EMBS Conference on*, 2013, pp. 81-84.
- [49] Li-Chen Shi, Ying-Ying Jiao, y Bao-Liang Lu, «Differential entropy feature for EEG-based vigilance estimation», en *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Osaka, 2013, pp. 6627-6630.
- [50] W.-L. Zheng, J.-Y. Zhu, Y. Peng, y B.-L. Lu, «EEG-based emotion classification using deep belief networks», en *2014 IEEE International Conference on Multimedia and Expo (ICME)*, Chengdu, China, 2014, pp. 1-6.
- [51] W.-L. Zheng, H.-T. Guo, y B.-L. Lu, «Revealing critical channels and frequency bands for emotion recognition from EEG with deep belief network», en *2015 7th International IEEE/EMBS Conference on Neural Engineering (NER)*, Montpellier, France, 2015, pp. 154-157.
- [52] «DEAP: A Dataset for Emotion Analysis using Physiological and Audiovisual Signals». [En línea]. Disponible en: <http://www.eecs.qmul.ac.uk/mmv/datasets/deap/readme.html>. [Accedido: 23-abr-2018].
- [53] J. D. Morris, «Observations: SAM: The Self-Assessment Manikin An Efficient Cross-Cultural Measurement Of Emotional Response», p. 6, 1995.
- [54] «SEED Dataset». [En línea]. Disponible en: <http://bcmi.sjtu.edu.cn/home/seed/index.html>. [Accedido: 16-sep-2018].
- [55] C. Jaganathan, A. Amudhavalli, T. Janani, M. Dhanalakshmi, y Nirmala Madian, «Automated algorithm for extracting  $\alpha$ ,  $\beta$ ,  $\delta$ ,  $\theta$  of a human EEG.pdf», *International Journal of Science, Engineering and Technology Research (IJSETR)*, vol. 4, 2015.
- [56] S. Butterworth, «On the theory of filter amplifiers», *Wireless Engineer*, vol. 7, n.º 6, pp. 536-541, 1930.
- [57] D. G. E. Robertson y J. J. Dowling, «Design and responses of Butterworth and critically damped digital filters», *Journal of Electromyography and Kinesiology*, vol. 13, n.º 6, pp. 569-573, dic. 2003.
- [58] M. X. Cohen, *Analyzing neural time series data: theory and practice*. MIT press, 2014.
- [59] S. Raschka, *Python machine learning second edition*. Packt Publishing Ltd, 2017.
- [60] C. Vidaurre, N. Krämer, B. Blankertz, y A. Schlögl, «Time Domain Parameters as a feature for EEG-based Brain-Computer Interfaces», *Neural Networks*, vol. 22, n.º 9, pp. 1313-1319, nov. 2009.
- [61] F. S. Bao, X. Liu, y C. Zhang, «PyEEG: An Open Source Python Module for EEG/MEG Feature Extraction», *Computational Intelligence and Neuroscience*, vol. 2011, pp. 1-7, 2011.
- [62] B. Kedem, «Spectral analysis and discrimination by zero-crossings», *Proceedings of the IEEE*, vol. 74, n.º 11, pp. 1477-1493, 1986.
- [63] G. Mejia, A. Gomez, y L. Quintero, «Reconocimiento de Emociones utilizando la Transformada Wavelet Estacionaria en Sen~ales EEG Multicanal», p. 5.
- [64] L. F. Márton, S. T. Brassai, L. Bakó, y L. Losonczy, «Detrended Fluctuation Analysis of EEG Signals», *Procedia Technology*, vol. 12, pp. 125-132, 2014.
- [65] C. Goh, B. Hamadicharef, G. Henderson, y E. Ifeachor, «Comparison of Fractal Dimension Algorithms for the Computation of EEG Biomarkers for Dementia», p. 9, 2005.
- [66] M. Cusenza, «Fractal analysis of the EEG and clinical applications», p. 125.

- [67] B. P. Harne, «Higuchi Fractal Dimension Analysis of EEG Signal Before and After OM Chanting to Observe Overall Effect on Brain», *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 4, n.º 4, ago. 2014.
- [68] D. Peña, *Fundamentos de estadística*. Alianza editorial, 2014.
- [69] R. Jenke, A. Peer, y M. Buss, «Feature Extraction and Selection for Emotion Recognition from EEG», *IEEE Transactions on Affective Computing*, vol. 5, n.º 3, pp. 327-339, jul. 2014.
- [70] A. H. Al-nuaimi, E. Jammeh, L. Sun, y E. Ifeachor, «Higuchi fractal dimension of the electroencephalogram as a biomarker for early detection of Alzheimer's disease», en *2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Seogwipo, 2017, pp. 2320-2324.
- [71] T. Higuchi, «Approach to an irregular time series on the basis of the fractal theory», *Physica D: Nonlinear Phenomena*, vol. 31, n.º 2, pp. 277-283, jun. 1988.
- [72] R. N. Bracewell y R. N. Bracewell, *The Fourier transform and its applications*, vol. 31999. McGraw-Hill New York, 1986.
- [73] M. X. Cohen, *Analyzing neural time series data: theory and practice*. MIT press, 2014.
- [74] J. L. Ferreira, Y. Wu, y R. M. Aarts, «Enhancement of the Comb Filtering Selectivity Using Iterative Moving Average for Periodic Waveform and Harmonic Elimination», *Journal of Healthcare Engineering*, vol. 2018, pp. 1-14, 2018.
- [75] J. L. Ferreira, R. M. Aarts, y P. J. M. Cluitmans, «Optimized moving-average filtering for gradient artefact correction during simultaneous EEG-fMRI», en *5th ISSNIP-IEEE Biosignals and Biorobotics Conference (2014): Biosignals and Robotics for Better and Safer Living (BRC)*, Salvador, Brazil, 2014, pp. 1-6.
- [76] M. Murugappan, N. Ramachandran, y Y. Sazali, «Classification of human emotion from EEG using discrete wavelet transform», *Journal of Biomedical Science and Engineering*, vol. 03, n.º 04, pp. 390-396, 2010.
- [77] I. Daubechies, «The wavelet transform, time-frequency localization and signal analysis», *IEEE Transactions on Information Theory*, vol. 36, n.º 5, pp. 961-1005, sep. 1990.
- [78] G. Pajares y J. De La Cruz, «Aprendizaje Automático un Enfoque Práctico», *RA-MA, Madrid*, p. 376, 2010.
- [79] S. S. Haykin, *Neural networks and learning machines*, vol. 3. Pearson Upper Saddle River, 2009.
- [80] C.-W. Hsu, C.-C. Chang, y C.-J. Lin, «A Practical Guide to Support Vector Classification», p. 16.
- [81] P. Dangeti, *Statistics for Machine Learning*. Packt Publishing Ltd, 2017.

## **A. Mapas de Color de las Búsquedas en Grid de las Pruebas Realizadas**

En este apéndice se exponen las imágenes de los mapas de color correspondientes a la búsqueda en grid de las pruebas realizadas, tanto con las características individuales como con los Supervectores de los 2 sets de datos utilizados en el estudio. Para ambos casos se realizaron pruebas con SVM Polinómico y RBF. Cada figura consta de 2 imágenes, representándose en la primera los valores de la búsqueda inicial en grid y en la segunda los valores de la búsqueda final en la que se encontraron los valores de parámetros óptimos de cada prueba.

En las imágenes se pueden observar en color rojo oscuro los valores correspondientes a los niveles de acierto de máximo valor, y en azul oscuro los valores correspondientes a los niveles de acierto de valor mínimo de cada prueba.

### **A.1. Pruebas Realizadas con Datos del Set SEED [9].**

En esta sección se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con el set de datos SEED [9].

#### **A.1.1. Características Extraídas (pre calculadas) del Set de Datos**

En esta sección se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con las características pre calculadas del set de datos SEED [9].

### A.1.1.1. Entropía Diferencial

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, tanto con el uso de PCA, como sin PCA.

#### SVM Polinómico con PCA Búsqueda en Grid




Figura 28 Entropía Diferencial: Búsqueda en grid SVM Polinómico con PCA

#### SVM Polinómico sin PCA Búsqueda en Grid




Figura 29 Entropía Diferencial: Búsqueda en grid SVM Polinómico sin PCA



SVM RBF con PCA Búsqueda en Grid




Figura 30 Entropía Diferencial: Búsqueda en grid SVM RBF con PCA

SVM RBF sin PCA Búsqueda en Grid

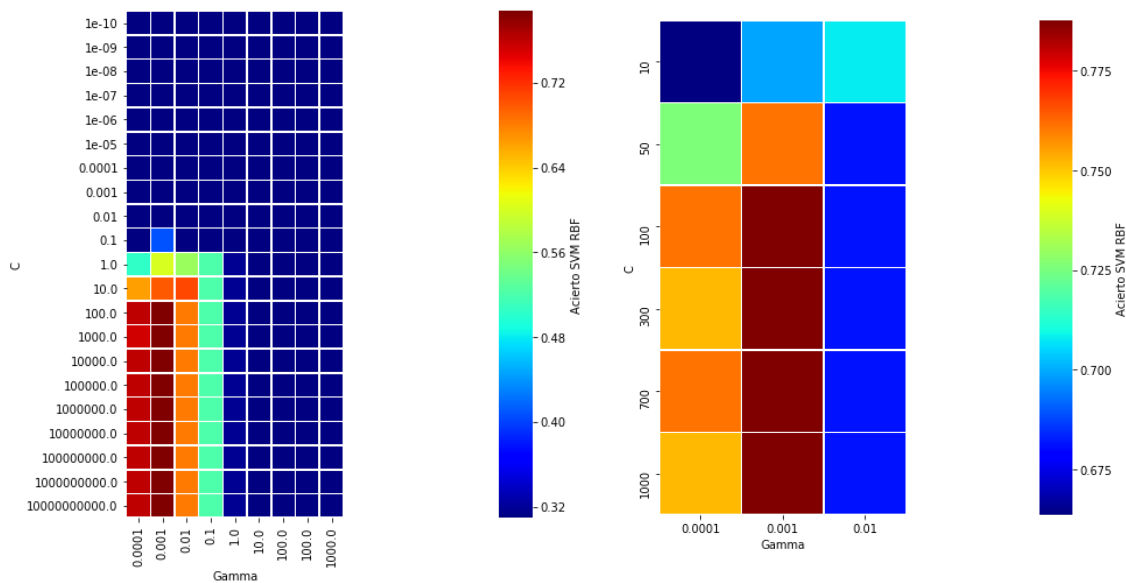


Figura 31 Entropía Diferencial: Búsqueda en grid SVM RBF sin PCA

### A.1.1.2. PSD con Media Móvil

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, tanto con el uso de PCA, como sin PCA.

#### SVM Polinómico con PCA Búsqueda en Grid:




Figura 32 PSD con Media Móvil: Búsqueda en grid SVM Polinómico con PCA

#### SVM Polinómico sin PCA Búsqueda en Grid:




Figura 33 PSD con Media Móvil: Búsqueda en grid SVM Polinómico sin PCA

**SVM RBF con PCA Búsqueda en Grid:**




Figura 34 PSD con Media Móvil: Búsqueda en grid SVM RBF con PCA

**SVM RBF sin PCA Búsqueda en Grid:**




Figura 35 PSD con Media Móvil: Búsqueda en grid SVM RBF sin PCA

### A.1.1.3. Supervector 0

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF con el uso de PCA.

**Características: Entropía Diferencial (DE) y PSD con Media Móvil**

**SVM Polinómico con PCA Búsqueda en Grid:**




Figura 36 Supervector 0: Búsqueda en grid SVM Polinómico con PCA

**SVM RBF con PCA Búsqueda en Grid:**




Figura 37 Supervector 0: Búsqueda en grid SVM RBF con PCA

### **A.1.2. Características Calculadas a partir de las Señales del Set de Datos**

En esta sección se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con las características calculadas a partir de las señales del set de datos SEED [9].

#### **A.1.2.1. Pruebas Individuales**

En esta sección se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con las características en forma individual.

#### **Media**

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, tanto con el uso de PCA, como sin PCA.

## SVM Polinómico con PCA Búsqueda en Grid:




Figura 38 Media: Búsqueda en grid SVM Polinómico con PCA

## SVM Polinómico sin PCA Búsqueda en Grid:




Figura 39 Media: Búsqueda en grid SVM Polinómico sin PCA

**SVM RBF con PCA Búsqueda en Grid:**




Figura 40 Media: Búsqueda en grid SVM RBF con PCA

**SVM RBF sin PCA Búsqueda en Grid:**




Figura 41 Media: Búsqueda en grid SVM RBF sin PCA

## Valor Máximo

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 42 Valor Máximo: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 43 Valor Máximo: Búsqueda en grid SVM RBF con PCA



## Mínimo

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 44 Valor Mínimo: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 45 Valor Mínimo: Búsqueda en grid SVM RBF con PCA

## Desviación Típica

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 46 Desviación Típica: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 47 Desviación Típica: Búsqueda en grid SVM RBF con PCA

**Sesgo o Asimetría**

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

**SVM Polinómico con PCA Búsqueda en Grid:**




Figura 48 Sesgo: Búsqueda en grid SVM Polinómico con PCA

**SVM RBF con PCA Búsqueda en Grid:**

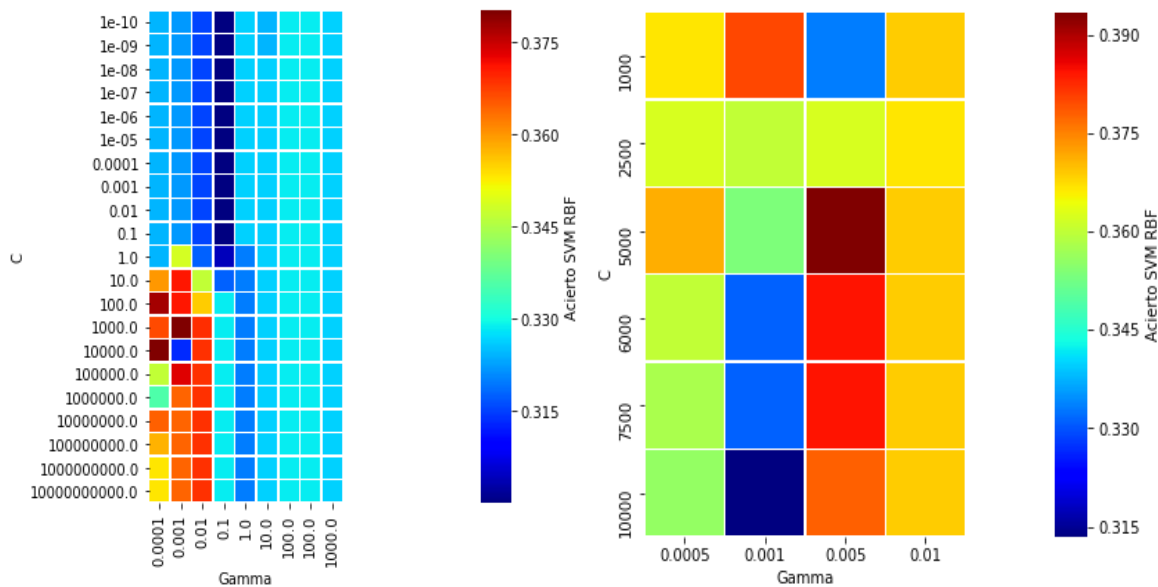


Figura 49 Sesgo: Búsqueda en grid SVM RBF con PCA

## Curtosis

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 50 Curtosis: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:

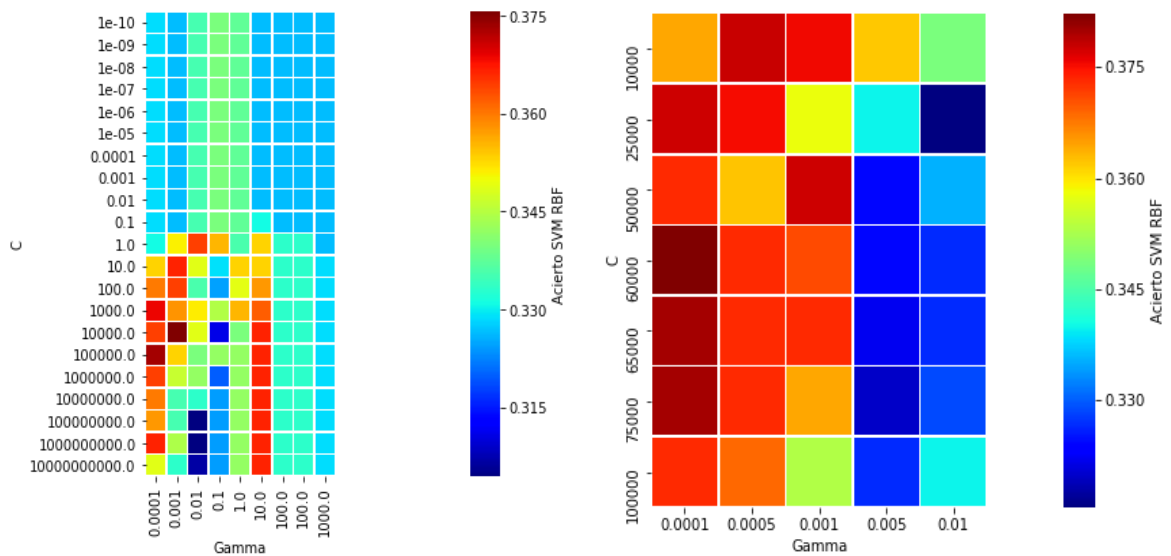


Figura 51 Curtosis: Búsqueda en grid SVM RBF con PCA

## HJORTH Movilidad

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 52 HJORTH Movilidad: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 53 HJORTH Movilidad: Búsqueda en grid SVM RBF con PCA

## HJORTH Complejidad

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 54 HJORTH Complejidad: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 55 HJORTH Complejidad: Búsqueda en grid SVM RBF con PCA

## Detrended Fluctuation Analysis (DFA)

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 56 DFA: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 57 DFA: Búsqueda en grid SVM RBF con PCA

## Cruces por Cero

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 58 Cruces por Cero: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 59 Cruces por Cero: Búsqueda en grid SVM RBF con PCA



### PSD Simple (Media)

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

#### SVM Polinómico con PCA Búsqueda en Grid:




Figura 60 PSD Simple (Media): Búsqueda en grid SVM Polinómico con PCA

#### SVM RBF con PCA Búsqueda en Grid:




Figura 61 PSD Simple (Media): Búsqueda en grid SVM RBF con PCA

## PSD Media Móvil (Media)

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 62 PSD Media Móvil (Media): Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 63 PSD Media Móvil (Media): Búsqueda en grid SVM RBF con PCA

## Wavelet db1 (Desviación Estándar)

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 64 Wavelet db1 (Desviación Estándar): Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 65 Wavelet db1 (Desviación Estándar): Búsqueda en grid SVM RBF con PCA

## Higuchi Fractal Dimension (HFD)

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 66 HFD: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 67 HFD: Búsqueda en grid SVM RBF con PCA

## Petrosian Fractal Dimension (PFD)

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 68 PFD: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 69 PFD: Búsqueda en grid SVM RBF con PCA

## Valencia

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 70 Valencia: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 71 Valencia: Búsqueda en grid SVM RBF con PCA

### A.1.2.2. Pruebas con Supervectores

En esta sección se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con las características combinadas en supervectores.

#### Supervector 1

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA**

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

#### SVM Polinómico con PCA Búsqueda en Grid:




Figura 72 Supervector 1: Búsqueda en grid SVM Polinómico con PCA

#### SVM RBF con PCA Búsqueda en Grid:




Figura 73 Supervector 1: Búsqueda en grid SVM RBF con PCA

## Supervector 2

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, Desviación Típica**

**SVM Polinómico con PCA Búsqueda en Grid:**




Figura 74 Supervector 2: Búsqueda en grid SVM Polinómico con PCA

**SVM RBF con PCA Búsqueda en Grid:**




Figura 75 Supervector 2: Búsqueda en grid SVM RBF con PCA



### Supervector 3

#### Características: HJORTH Complejidad, HJORTH Movilidad, DFA

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

#### SVM Polinómico con PCA Búsqueda en Grid:




Figura 76 Supervector 3: Búsqueda en grid SVM Polinómico con PCA

#### SVM RBF con PCA Búsqueda en Grid:

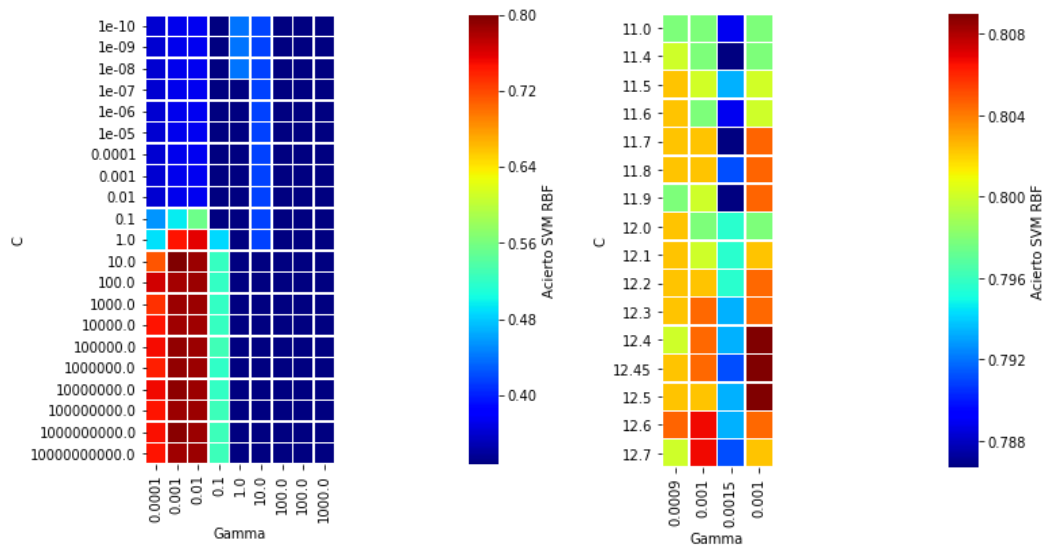


Figura 77 Supervector 3: Búsqueda en grid SVM RBF con PCA

## Supervector 4

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD**

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 78 Supervector 4: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 79 Supervector 4: Búsqueda en grid SVM RBF con PCA

## Supervector 5

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Cruces por Ceros**

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 80 Supervector 5: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 81 Supervector 5: Búsqueda en grid SVM RBF con PCA

## Supervector 6

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Cruces por Cero**

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 82 Supervector 6: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 83 Supervector 6: Búsqueda en grid SVM RBF con PCA

## Supervector 7

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Wavelet db1, Cruces por Ceros**

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 84 Supervector 7: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 85 Supervector 7: Búsqueda en grid SVM RBF con PCA

## Supervector 8

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Cruces por Ceros, Valencia**

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM Polinómico y RBF, en ambos casos solo con PCA.

### SVM Polinómico con PCA Búsqueda en Grid:




Figura 86 Supervector 8: Búsqueda en grid SVM Polinómico con PCA

### SVM RBF con PCA Búsqueda en Grid:




Figura 87 Supervector 8: Búsqueda en grid SVM RBF con PCA

## A.2. Pruebas Realizadas con Datos del Set DEAP [8].

En esta sección se exponen las imágenes de la búsqueda en grid de las pruebas realizadas con las características calculadas a partir de las señales del set de datos DEAP [8].

### Supervector DEAP 1

**Características: HJORTH Complejidad, HJORTH Movilidad, HFD, DFA, PFD, Desviación Típica, Cruces por Ceros,**

Se exponen las imágenes correspondientes a la búsqueda en grid de las pruebas realizadas con SVM RBF con PCA.




Figura 88 Supervector DEAP 1: Búsqueda en grid SVM RBF con PCA